

ESTRATEGIA DE INVERSIÓN BASADA EN UN MODELO NEURONAL BORROSOS ENFOCADO EN LA ESTRUCTURACIÓN DE PORTAFOLIOS EN TIEMPO REAL

SANTIAGO CORREAL CARVAJAL

Trabajo de grado para optar al título de Ingeniero Financiero

Alejandro Peña Palacio, IM, MSc, PhD



**UNIVERSIDAD EIA
INGENIERIA FINANCIERA
ENVIGADO
2018**

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

CONTENIDO

	pág.
INTRODUCCIÓN.....	8
1. PRELIMINARES	10
1.1 Planteamiento del problema	10
1.2 Objetivos del proyecto	11
1.2.1 Objetivo General	11
1.2.2 Objetivos Específicos	11
1.3 Marco de referencia.....	11
1.3.1 Antecedentes	11
Marco teórico	13
1.3.2 Series de tiempo:	13
1.3.3 Tipos e identificación:.....	13
1.3.4 Transformaciones en series de tiempo.....	15
1.3.5 Pronósticos de datos usando los modelos	17
1.3.6 Teoría de portafolios	18
1.3.7 Razón de Sharpe.	19
1.3.8 Redes Neuronales.....	20
1.3.9 Composición del Dow Jones	22
2. METODOLOGÍA	29
2.1 Analizar el comportamiento de los activos que componen el Dow Jones Industrial Average mediante series de tiempo teniendo en cuenta las tendencias y los cambios en la volatilidad.	29

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

2.2	Desarrollar un modelo neuronal para la estimación del comportamiento del precio y de la volatilidad de cada uno de los activos analizados para cada periodo.	29
2.3	Desarrollar la estrategia de inversión propuesta mediante la integración de los modelos neuronales diseñados anteriormente	30
2.4	Validar el comportamiento de la estrategia de inversión de acuerdo con la conformación del portafolio y la ganancia a largo plazo.....	32
3.	PRESENTACIÓN Y DISCUSIÓN DE RESULTADOS	33
3.1	Comportamiento de las series de precios.	33
3.2	Análisis de autocorrelación de las series de precios.	43
3.3	Estructura de la red neuronal.....	51
3.4	Resultados del modelo neuronal en la predicción de precios.....	53
3.5	Resultados de Backtesting para diferentes franjas de tiempo	62
3.5.1	Periodos Semestrales	62
3.5.2	Periodos Anuales	64
3.5.3	Periodos Trimestrales	65
3.5.4	Análisis comparativo adicional	69
4.	CONCLUSIONES Y CONSIDERACIONES FINALES	70
	REFERENCIAS	72
	ANEXOS	76
4.1	Anexo 1: Código de la red neuronal.....	76
4.2	Anexo 2: Código en R para las gráficas de autocorrelación	77
4.3	Anexo 3: Código completo para correr la estrategia y backtesting	78
4.4	Anexo 4: Código usado para generar outputs de Simulink.....	80

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

LISTA DE TABLAS

	pág.
Tabla 1: Correlaciones Volumen, Precio y RSI	42
Tabla 2: Resumen de la información de las series de tiempo	43
Tabla 3: Error cuadrático medio	62

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

LISTA DE ANEXOS

	pág.
4.1 Anexo 1: Código de la red neuronal.	78
4.2 Anexo 2: Código en R para las gráficas de autocorrelación	79
4.3 Anexo 3: Código completo para correr la estrategia y backtesting	80
4.4 Anexo 4: Código usado para generar outputs de Simulink	82

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

RESUMEN

¿Existe alguna manera de predecir el comportamiento de los activos que componen el Dow Jones mediante el uso de redes neuronales, de modo que se pueda lograr obtener un retorno superior al que alcanza este índice y disminuyendo el riesgo que esta inversión implica? En este trabajo se busca desarrollar una estrategia de inversión que, mediante el uso de algoritmos de aprendizaje y econometría, permita identificar en tiempo real la composición ideal de un portafolio de activos financieros, de modo que se optimice la relación rentabilidad riesgo. Para tal efecto se desarrolló una herramienta automatizada que permitió elaborar pronósticos de la rentabilidad y la volatilidad condicional de un conjunto de activos seleccionados, con lo cual se logró determinar cuáles son los activos ideales para invertir.

En este trabajo se integran las nuevas tendencias de trading algorítmico con los métodos tradicionales de estructuración de portafolios, logrando desarrollar un modelo de inversión dinámico que se ajuste a los cambios en las condiciones de mercado.

Palabras clave: Portafolio, Riesgo, Rentabilidad, Redes Neuronales

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

ABSTRACT

Is there any method to predict how Dow Jones' assets will change their prices in time using neural networks, in order to generate higher returns than those generated by the index itself? This paper aims to develop an investment strategy that, using econometrics and machine learning, allows us to identify the optimal portfolio composition of a selected group of assets. This is achieved with the optimization of the return/volatility ratio. We developed a tool able to forecast the return of the assets analyzed as well as the conditional volatility. With these forecasts are selected the assets which will be bought.

This thesis integrates new tendencies of algorithmic trading with traditional methods of portfolio management to develop a dynamic investment model which is able to adjust itself to unexpected changes of the market conditions.

Key words: Portfolio Management, Risk, Return, Neural networks

INTRODUCCIÓN

¿Existe alguna manera de predecir el comportamiento de los activos que componen el Dow Jones mediante el uso de redes neuronales, de modo que se pueda lograr obtener un retorno superior al que alcanza este índice y disminuyendo el riesgo que esta inversión implica? En este trabajo se buscará desarrollar un modelo dinámico para la consolidación de portafolios de inversión basándose en la optimización de la relación riesgo retorno de los pronósticos de ambas variables.

Para alcanzar este objetivo, se utilizó un modelo de redes neuronales lineales multicapa para lograr la predicción del precio y posteriormente su rendimiento. Para esto se tomó como referencia el trabajo de Dip & Romero (2015) en donde se utilizaban modelos neuronales para predecir el precio en acciones de telefonía.

Otra variable importante para predecir en la estrategia de inversión es la volatilidad del activo. Para esto se recurrió a un modelo propuesto por Arneric, Poklepović, & Aljinović (2014), en donde se utiliza el cuadrado de los errores de predicción de la serie de retornos, para entrenar una nueva red neuronal que simule un modelo Garch. En este trabajo se utilizará una red neuronal Madaline para la predicción de esta variable utilizando una estructura autorregresiva del cuadrado del error de predicción.

Para el cálculo de la volatilidad conjunta del portafolio de inversión se hizo uso de una matriz de correlación condicional constante (CCC) siguiendo la metodología descrita por Rossi (2010) donde calculan la covarianza de un modelo Garch multivariado mediante el uso de las varianzas condicionales de los activos individuales y las correlaciones de los activos encontradas en la muestra de datos evaluadas.

Por último, buscando obtener una ponderación de cada activo objetiva donde se estuviera optimizando la relación de rentabilidad y riesgo se tomo como referencia la Optimización estocástica mediante métodos de Monte Carlo utilizada por Serrano (2011) donde se evaluaban para cada periodo 10 millones de combinaciones posibles de modo que se pudiera encontrar la que mejor relación encontraba.

Para delimitar el alcance del proyecto, se optó por focalizar el desarrollo de la herramienta en las 30 acciones que componen el Dow Jones Industrial Average. De este modo, el portafolio que genera la estrategia desarrollada dependerá de las posiciones activas que arroje el modelo durante los periodos de tiempo evaluados. Por otro lado, la composición porcentual que tendrán las posiciones activas se calcula mediante una simulación donde se busca optimizar la relación de retorno y rentabilidad.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Los resultados obtenidos por el modelo propuesto entregan retornos positivos en la totalidad de las franjas de tiempo evaluadas entre los años 2016 y 2018. Sin embargo, estos retornos no siempre logran superar el desempeño que se alcanzaría invirtiendo bajo la metodología “buy & hold” en el índice durante la misma franja de tiempo. En el trabajo se encontrará una descripción más detallada de como fue el desempeño de la estrategia desarrollada.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

1. PRELIMINARES

1.1 PLANTEAMIENTO DEL PROBLEMA

Antes de que Henry Markowitz presentara su tesis doctoral “Selección de portafolios” en 1952, los inversionistas sólo prestaban atención a la maximización de los retornos esperados de un portafolio sin tener en cuenta el riesgo al cual estos se exponían al invertir en un activo específico. Markowitz, (1952) plantea que el inversionista no sólo se debe preocupar por la rentabilidad ofrecida por un portafolio, sino que también debe tener en cuenta su nivel de aversión al riesgo. A partir de este planteamiento, se empieza a buscar que, para un nivel específico de riesgo, se espere obtener la máxima rentabilidad posible.

En la actualidad, las nuevas tendencias de inversión en el mercado de capitales se inclinan al desarrollo de herramientas automatizadas que invierten en activos específicos de acuerdo con los datos históricos que se pueden encontrar. Para esto se puede acudir a dos opciones: en primer lugar, a la econometría, usando modelos auto-regresivos y de medias móviles (ARMA) para pronosticar el comportamiento en el corto plazo de los activos basado en las series de tiempo y; en segundo lugar, al desarrollo de redes neuronales que aprendan el comportamiento del activo en el tiempo y que permitan predecir su tendencia. (Shen, 2015)

Por otro lado, en la econometría, desde Jim Tinbergen en 1969, se vienen desarrollando modelos dinámicos que permiten la predicción del comportamiento de las variables en el corto plazo. Estas predicciones se basan en el análisis de series de tiempo que evalúan el comportamiento histórico de los activos y permiten hacer una aproximación del comportamiento futuro.

Al considerar el pronóstico en el comportamiento de los activos y las técnicas de estructuración de portafolio, se podría plantear el desarrollo de una estrategia que, considerando una lista predefinida de activos del mercado de capitales, evaluara en tiempo real las cantidades óptimas a invertir en estos activos y los momentos en que se debe invertir, optimizando las medidas de desempeño existentes como la de Sharpe. (Serrano, 2005)

Esta estrategia deberá evaluar la diversificación óptima para poner en los activos tratados y, esta deberá ser actualizada en tiempo real de manera automatizada, sin la necesidad de esperar periodos de rebalanceo.

Para desarrollar esta estrategia, se requiere de una herramienta que evalúe en tiempo real el comportamiento esperado de todos los activos considerados y, de igual manera, que calcule las volatilidades y correlaciones esperadas para los

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

mismos. Esto con el fin de que, para cada señal de salida o entrada a un activo, se pueda optimizar la composición nueva del portafolio que haría que este maximice su desempeño de acuerdo al perfil de riesgo seleccionado. Todo lo descrito anteriormente, debe tener en cuenta los costos de comisión por operar pues estos distorsionan los retornos finales.

Por lo tanto, la propuesta busca solucionar la pregunta ¿Cómo se comporta la estructuración de un portafolio óptimo de inversión, al considerar los pronósticos de las volatilidades y los retornos entregadas por los modelos con efectos GARCH en los activos evaluados?

1.2 OBJETIVOS DEL PROYECTO

1.2.1 Objetivo General

Desarrollar una estrategia de inversión para la estructuración de portafolios, basada en un modelo neuronal borroso integrado, para el ajuste de la relación de volatilidad y rentabilidad.

1.2.2 Objetivos Específicos

- Analizar el comportamiento de los activos que componen el Dow Jones Industrial Average mediante series de tiempo teniendo en cuenta las tendencias y los cambios en la volatilidad.
- Desarrollar un modelo neuronal borroso para la estimación del comportamiento del precio y de la volatilidad de cada uno de los activos analizados para cada periodo.
- Desarrollar la estrategia de inversión propuesta mediante la integración de los modelos neuronales diseñados anteriormente utilizando la plataforma meta trader.
- Validar el comportamiento de la estrategia de inversión de acuerdo con la conformación del portafolio y la ganancia a largo plazo

1.3 MARCO DE REFERENCIA

1.3.1 Antecedentes

Durante los últimos años, con el auge de la tecnología y con las facilidades que han desarrollado los mercados internacionales para el ingreso de pequeños

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

inversionistas en el mercado de capitales, se han popularizado tendencias de trading algorítmico, las cuales consisten en el uso de herramientas matemáticas e informáticas para la detección de movimientos alcistas o bajistas que permitan la toma de decisiones al momento de invertir. (Treleaven, Galas & Lalchand, 2013).

Desde 1995 ya se empezaban a presenciar proyectos que buscaban encontrar patrones para la ejecución automática de órdenes de compra y venta de acuerdo a las condiciones de mercado. Uno de los proyectos pioneros en el trading algorítmico, fue el de la firma Long Term Capital LTCM, que tras el desarrollo de la fórmula de Black & Scholes, buscaba eliminar el riesgo de las inversiones, garantizando una rentabilidad en el largo plazo. Pese a que en un principio esta estrategia funcionó, la presencia de choques en el mercado, afectaron la volatilidad de los activos financieros y este cambio no pudo ser replicado por el modelo desarrollado. La consecuencia de esto fue la pérdida de miles de millones de dólares y el cierre de la firma LTCM en 1998. (Ailon, 2012).

Después de este incidente, quedó un sentimiento de desconfianza frente a las estrategias de trading automatizado. Sin embargo, el avance en la computación y el desarrollo de nuevas teorías económicas, dieron paso a que se siguiera estudiando esta disciplina. Mas adelante, Kia, Jeney & Levendovszky (2014), desarrollaron un modelo para minimizar las pérdidas esperadas en la ejecución de trading algorítmico, mediante el uso del supuesto de que los activos seguían un proceso de Leví. En este trabajo, se encontraron los valores de los parámetros que ajustaban los activos tratados y se hizo un análisis con las acciones de S&P500. Una vez desarrollado el modelo, se hizo un backtesting histórico comparando el rendimiento obtenido con el mercado. El resultado de este proyecto fue obtener un rendimiento de 4.8% anual por encima del mercado, demostrándose la efectividad del modelo.

Berutich, López, Luna & Quintana (2016), desarrollaron una estrategia de trading algorítmico basada en programación genética. El objetivo del proyecto era encontrar reglas generalizadas para la identificación de señales de compra y venta de activos pertenecientes al mercado español, teniendo en cuenta la sensibilidad de los mismos a las variables como volatilidad, CAPM y retorno esperado y re balanceando la composición de los portafolios basándose en las señales entregadas por la estrategia. La estrategia desarrollada fue probada mediante un backtesting entre los años 2009 y 2013, obteniendo un retorno de 31.81% sobre la inversión, mientras que el IBEX, solo había rendido un 2.67%.

Por otro lado, Yadav (2015), plantea como el trading algorítmico quebranta la eficiencia de los mercados, al mostrar como el efecto de realizar operaciones basadas en proyecciones del comportamiento de los activos y su pasado, nubla la realidad del comportamiento de las empresas y de los rendimientos de las mismas,

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

abriendo una brecha amplia para la especulación y para la sobrevaloración de los activos.

Todos los modelos de trading algorítmico se caracterizan por la búsqueda de señales de compra y venta de modo que se puedan obtener rendimientos por encima del mercado, basándose en la información estadística que busca el modelo. El problema de los modelos citados es que subestiman el riesgo, en este trabajo, al tomarse en consideración los cambios en las varianzas condicionales de los activos.

Marco teórico


1.3.2 Series de tiempo:

La expresión series de tiempo se utiliza para denotar una secuencia de observaciones numéricas ordenadas en el tiempo bajo una frecuencia constante. En economía e inversión, las series de tiempo registran el movimiento de un activo financiero durante un periodo de tiempo específico. Esta herramienta es usada en econometría para el análisis de datos y para el pronóstico del comportamiento de los activos de acuerdo a los modelos desarrollados. (Giraldo, N. 2006).

1.3.3 Tipos e identificación:

De acuerdo con su comportamiento, las series de tiempo pueden ser clasificadas en estacionarias o con tendencia. Estas series, adicionalmente pueden tener un componente estacional.


Se dice que una serie cuenta con un componente estacionario si su comportamiento siempre oscila alrededor de un mismo eje horizontal. Comúnmente, los retornos logarítmicos de los activos tienen esta característica (Bodie, Z., Kane, A., & Marcus, A. J, 2004). En la gráfica 4.1 se muestra cómo se ve el comportamiento de estas series representado en un plano cartesiano.



Gráfica 4.1 (elaboración propia)


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Por otro lado, cuando las observaciones de una serie de tiempo muestran un comportamiento creciente o decreciente en el largo, se dice que las series tienen un componente con tendencia. Ejemplo de esto es el precio de algunos activos financieros que en el tiempo se valorizan o desvalorizan de acuerdo a su naturaleza. En la gráfica 4.2 se muestra cómo se ve el comportamiento de estas series representado en un plano cartesiano. (Giraldo, N. 2006).



Gráfica 4.2 (elaboración propia)

Por último, las series de tiempo también pueden tener un patrón de repetición en el tiempo independientemente de que tengan un componente estacionario o de tendencia. Cuando las series tienen esta característica, se dice que la serie es estacional. En la gráfica 4.3 se muestra cómo se ve el comportamiento de estas series.



Gráfica 4.3: Serie estacional (elaboración propia)}

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Para identificar el tipo de serie de tiempo que se tiene, se puede hacer uso de la observación y determinar el tipo de serie empíricamente o se puede hacer uso de diagrama de autocorrelación entre las observaciones.

Si en la serie hay tendencia, quiere decir que hay una correlación cercana a 1 en la primera banda del correlograma y esta empieza a decrecer lentamente. Si la serie es estacionaria, los valores de la autocorrelación decaen rápidamente a cero en el correlograma. Por último, si la serie es estacional, la autocorrelación en el rezago estacional y/o sus múltiplos es estadísticamente diferente de cero. (Giraldo, N. 2006).

1.3.4 Transformaciones en series de tiempo

En este trabajo, los pronósticos de los activos se harán con técnicas aplicadas a las series de tiempo estacionarias. Sin embargo, el precio de los activos no es explicado por estas series (Montero, R. 2013). Por este motivo, es necesario realizar transformaciones a las observaciones que se tienen para poder hacer uso de estos modelos.

La transformación que se usará será la de diferenciar logarítmicamente las observaciones para obtener los retornos logarítmicos de los activos. Empíricamente se ha demostrado que la mayoría de los retornos de los activos tienden a seguir un comportamiento estacional (Montero, R. 2013).

- Modelos para pronósticos de series estacionarias

La mayoría de los modelos desarrollados en econometría son aplicables a series de tiempo estacionarias. Los más comunes son los autorregresivos y de medias móviles que se caracterizan porque tratan de explicar el comportamiento de las series a partir de su propio pasado (Montero, R. 2013).

⇒ Modelos AR(p)

El modelo autorregresivo de orden p para la serie de tiempo estacionaria Y_t tiene la estructura:

$$y_t = \phi_0 + \phi_1 * y_{t-1} + \phi_2 * y_{t-2} + \dots + \phi_p * y_{t-p} + \epsilon_t \quad (1)$$

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Esta serie está en función de sus rezagos. Y su polinomio de rezagos se expresa de la forma:

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) * y_t = \phi_0 + \epsilon_t \quad (2)$$

ϕ_n son los parámetros del modelo y se debe cumplir que las raíces del polinomio de rezagos caigan se encuentren por fuera del círculo unitario y que la suma de los parámetros sea menor que 1. Si estas condiciones no se cumplen, significa que la serie no es estacionaria. (Giraldo, N. 2006).

ϵ_t es el error de la estimación y debe seguir un proceso ruido blanco

⇒ Modelos MA(q)

El modelo de medias móviles de orden q para la serie de tiempo estacionaria Y_t tiene la estructura:

$$y_t = \theta_0 + \epsilon_t - \theta_1 * \epsilon_{t-1} - \theta_2 * \epsilon_{t-2} - \dots - \theta_q * \epsilon_{t-q} \quad (3)$$

Y su polinomio de rezagos se escribe de la forma

$$y_t = \theta_0 + (1 - \theta_1 L^1 - \theta_2 L^2 - \dots - \theta_q L^q) * \epsilon_t \quad (4)$$

En este caso, Y_t Se encuentra en función de las perturbaciones y θ_n son los parámetros del modelo. (Giraldo, N. 2006).

⇒ Modelos ARMA (p,q)

Este modelo está desarrollado para series estacionarias y se escribe en función de su propio pasado y de sus perturbaciones. La estructura del modelo es:

$$y_t = \phi_0 + \phi_1 * y_{t-1} + \phi_2 * y_{t-2} + \dots + \phi_p * y_{t-p} + \epsilon_t - \theta_1 * \epsilon_{t-1} - \theta_2 * \epsilon_{t-2} - \dots - \theta_q * \epsilon_{t-q} \quad (5)$$

En este modelo se debe cumplir que las raíces de los polinomios de rezagos de la parte AR y MA no sean iguales. Este modelo es estacionario si las raíces del polinomio de rezagos de la parte AR cae por fuera del círculo unitario e invertible si las raíces del polinomio de rezagos de la parte MA cae por fuera del círculo unitario (Giraldo, N. 2006).

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

⇒ Modelos de la GARCH (p,q)

Para que un modelo este correcto, se requiere que este explique correctamente la dinámica de la volatilidad de la serie de tiempo. Como esto no siempre ocurre en los modelos ARMA, se han desarrollado modelos de heteroscedasticidad condicional que permiten ajustar la volatilidad de la serie de tiempo. Estos modelos son escritos de la siguiente manera.

$$\vartheta_t^2 = \delta_0 + \delta_1 * \vartheta_{t-1}^2 + \delta_2 * \vartheta_{t-2}^2 + \dots + \delta_p * \vartheta_{t-p}^2 + \epsilon_t^2 - \theta_1 * \epsilon_{t-1}^2 - \theta_2 * \epsilon_{t-2}^2 - \dots - \theta_q * \epsilon_{t-q}^2 \quad (6)$$

En estos modelos, la varianza condicional en el periodo t de la serie es explicada por los cuadrados de los errores y los rezagos de la varianza condicional. (Alzghool. 2017).

El modelos GARCH (p,q) puede ser escrito como un modelo ARIMA para el cuadrado de los errores del modelo que explica la serie de tiempo

1.3.5 Pronósticos de datos usando los modelos

Una vez se tienen los modelos estimados, la predicción extra muestral de la serie de tiempo analizada, se obtiene reemplazando en la formula obtenida los valores que se tienen de las observaciones.

1.3.2.3 Matriz de correlación condicional constante (CCC)

Tomando como punto de partida la estimación de las volatilidades en los modelos garch observados, se puede hacer una estimación de las covarianzas entre un grupo de activos n analizados haciendo uso de la matriz de correlaciones constantes.

El cálculo de la matriz de correlaciones se puede hacer con los datos muestrales utilizando la fórmula:

$$\rho_{X,Y} = \text{corr}(X, Y) = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{\sigma_X \sigma_Y}, \quad (7)$$

Posteriormente, con los pronósticos de las varianzas obtenidos, se puede escribir la matriz de varianzas y covarianzas de la forma:

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

$$CCC = diag(\sigma_i) * \rho_{ij} * diag(\sigma_i) \quad (8)$$

(Rossi, 2010)

1.3.6 Teoría de portafolios

Un portafolio de inversión es una selección de instrumentos financieros en la cual se espera obtener una rentabilidad específica de acuerdo al riesgo asumido por la persona que invierte.

En el mercado de capitales se pueden encontrar instrumentos de renta fija y renta variable que pueden ser seleccionados en la conformación de un portafolio. Sin embargo, al momento de elegir los activos es necesario tener en cuenta el riesgo que constituyen los activos, la media de rentabilidad esperada y la correlación entre los activos a seleccionar. (Bodie, Z., Kane, A., & Marcus, A. J, 2004).

- Media de rentabilidad, Riesgo y Correlación

La rentabilidad de un activo está definida como el cambio porcentual del activo en un periodo de tiempo determinado. Cuando se tienen varios periodos de tiempo de una misma longitud, se utiliza la rentabilidad promedio para estimar el rendimiento esperado del activo para un periodo. Esta puede ser escrita de la forma:

$$Rentabilidad\ Promedio = \frac{R_1 + R_2 + R_3 + \dots + R_n}{n} \quad (9)$$

En un portafolio, la rentabilidad debe ser calculada de forma ponderada de acuerdo a la participación que cada activo tenga dentro del mismo. (Jorion, 2011)

$$R = \sum_{n=1}^N w_n R_n \quad (10)$$

Donde $W_n = X_n / X$ y X_n es el dinero invertido en el activo n y X es el monto total invertido.

Una manera de medir el riesgo es usando la volatilidad de los retornos del activo. (Grigoriu, 2011). Este indica que tanto se desvían los retornos del valor esperado y se calcula como la raíz de la varianza de los retornos.

$$\sigma^2 = \frac{\sum_{t=1}^T (R_t - \bar{R})^2}{T - 1} \quad (11)$$

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

La covarianza mide a qué extensión se mueven dos variables juntas en el tiempo. Una covarianza positiva significa que las dos variables tienden a moverse en la misma dirección mientras que una covarianza negativa significa que las variables tienden a moverse en direcciones opuestas. Esta es calculada de la siguiente manera. (Jorion, 2011).

$$Cov_{1,2} = \frac{\sum_{t=1}^n ((R_{t,1} - \bar{R}_1)(R_{t,2} - \bar{R}_2))}{n - 1} \quad (12)$$

La correlación es una estandarización de la covarianza y permite su interpretación. Esta muestra porcentualmente, que tan relacionados se encuentran 2 activos y se calcula de la forma:

$$\rho_{1,2} = \frac{Cov_{1,2}}{\sigma_1 \sigma_2} \quad (13)$$

Para la selección de portafolios, es utilizado la maximización de la relación riesgo rentabilidad, pues esta garantiza que, para un nivel de riesgo dado, se está obteniendo la máxima rentabilidad posible. (Bodie, Z. et al, 2004).

Se debe tener en cuenta que en un portafolio el riesgo se escribe como:

$$V_p = \sum_{n=1}^N w_n^2 \sigma_n^2 + 2 \sum_{n < m} w_n w_m \sigma_n \sigma_m \rho_{n,m} \quad (14)$$

1.3.7 Razón de Sharpe.

La razón de Sharpe muestra la relación entre el exceso de rendimiento de un instrumento financiero con el mercado al que pertenece y su volatilidad. Partiendo de esto, el indicador es interpretado como el rendimiento que se espera obtener por encima del mercado, por cada unidad de riesgo asumida al invertir en un activo específico (Jorion, 2011). De este modo, la razón de Sharpe puede ser expresada como.


$$RS = \frac{\mu_a - R_m}{\sigma_a} \quad (15)$$

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Donde RS es la razón de sharpe, μ_a es la rentabilidad esperada del activo financiero, R_m es la rentabilidad esperada del mercado y ϑ_a es la desviación estándar del activo en cuestión.

1.3.8 Redes Neuronales

Una máquina neuronal se caracteriza porque esta “elabora”, la información de entrada para obtener una salida o respuesta. La neurona artificial, es un elemento que posee un estado interno, llamado nivel de activación y recibe señales que le permiten cambiar su estado. La función de activación es definida por el usuario. En la gráfica 4.4 se muestra como es el proceso. (Isasi Viñuela & Galván León, 2004)




Gráfica 4.4 (Isasi Viñuela, et al, 2004)

- Estructura de una red neuronal

En la figura 4.2 se ve una unidad típica de proceso de una red neuronal, a la izquierda se tiene una serie de entradas a la neurona; cada una llega de la salida de otra neurona de la red. Una vez calculada de una neurona, esta se propaga vía conexiones de salida, a las células de destino.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



Gráfica 4.5: esquema de una red de tres capas totalmente interconectadas (Isasi Viñuela, et al, 2004)

A la manera en que las células se conectan entre sí se le denomina patrón de conectividad o arquitectura de la red. Esta estructura se puede observar en la gráfica 4.5. El primer nivel lo constituyen las células de entrada; estas unidades reciben los valores de unos patrones representados como vectores que sirven de entrada a la red. A continuación, hay una serie de capas intermedias que responden a rasgos que pueden aparecer gracias a los patrones de entrada y por último se encuentra el nivel de salida de la red. (Isasi Viñuela, et al, 2004).

El patrón de funcionamiento de una red de neuronas por capas, puede definirse como:

$$\vec{S} = F(F(\vec{X}.W_1).W_2) \quad (16)$$

Donde F es la función de activación, X es el vector de entrada a la red, S es el vector de salida y W1 y W2 son matrices de conexiones entre las capas de la red que en primera instancia, son los pesos de la primera y la segunda capa.

- Algoritmos de aprendizaje

El esquema de aprendizaje de una red es el que determina el tipo de problema que se va a desarrollar. La capacidad de una red para resolver un problema está ligada a la información que tiene el proceso de aprendizaje. Este proceso deberá tener un conjunto de ejemplos significativos y representativos de modo que pueda adaptarse al comportamiento del fenómeno que está replicando.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

El aprendizaje en una red neuronal consiste en la determinación de los valores de los pesos de sus conexiones, que la capacite para la resolución eficiente de un problema. Una vez se introducen todos los ejemplos, se debe verificar que exista un criterio de convergencia de modo que se pueda finalizar el proceso de aprendizaje. Según Isasi Viñuela, et al (2004), el proceso de aprendizaje puede describirse en los siguientes pasos: Asignar a los pesos valores aleatorios; introducir todos los ejemplos del conjunto de entrenamiento, modificando los pesos de acuerdo con el esquema de aprendizaje; introducir todos los ejemplos del conjunto de validación y obtener el error entre los valores producidos por los ejemplos y los reales; si el error está por encima de un margen definido, regresar al paso inicial, sino; acabar el proceso de aprendizaje y dar como salida la red obtenida.

1.3.9 Composición del Dow Jones

Por este motivo, el benchmark que se buscará superar será el índice DJIA que se compone de una acción de cada una de las compañías que lo forman. A continuación, se realizará una descripción de las acciones que componen el DJIA.

- **The Boeing Company**

Esta empresa “desarrolla, produce y comercia Jets comerciales, así como provee servicios relacionados de soporte a la industria global de aerolíneas.” (Bloombergg, 2018) Fue fundada en 1916 y hace parte del DJIA desde 1987. Adicionalmente, la compañía estudia, desarrolla y produce sistemas espaciales y de defensa. Esto también incluye aeronaves con propósitos militares. (Bloombergg, s/f-a)

- **UnitedHealth Group Incorporated**

UnitedHealth Group Incorporated “posee y gestiona sistemas organizados de sanidad en los Estados Unidos y todo el mundo” (Bloombergg, s/f-ba). Fue fundada en 1977 y hace parte del DJIA desde 1987 el 2012. La empresa Provee productos y recursos a otras empresas para la planeación y gestión de beneficios de empleados. (Bloombergg, s/f-b)

- **The Goldman Sachs Group, Inc**

The Goldman Sachs Group, Inc., es una de las bancas de inversión más grandes a nivel internacional. Se especializa en inversiones bancarias, trading y administración de activos. Fue fundada en 1869 y forma parte del DJIA desde 2013. La empresa presta servicios a corporaciones, instituciones financieras, gobiernos y personas con un alto patrimonio. (Bloombergg, s/f-ca)

- **3M Company**

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

“3M Company opera mercados de electrónica, telecomunicaciones, industriales, consumo y oficina, sanidad, seguridad y otros.” (Bloombergg, s/f-d). La empresa fue fundada en 1902 e ingreso al DJIA en 1976. A 2017 tenía activos por 38 billones de dólares. Sus negocios comparten tecnología, operaciones manufactureras, canales de mercadotecnia y otros recursos. (Bloombergg, s/f-d)

- **Apple Inc.**

Apple Inc. diseña, produce y comercializa computadores personales, dispositivos móviles de comunicación y softwares relacionados con soluciones digitales. Sus productos son vendidos a nivel internacional a través de su tienda en línea, su fuerza comercial en tiendas físicas y alianzas con terceros. La empresa fue fundada en 1976, ingreso al DJIA en 2015 y cuenta con activos a 2017 por un valor de 317 billones de dólares. (Bloombergg, s/f-e)

- **The Home Depot, Inc**

“The Home Depot, Inc. es un vendedor minorista de productos para el mejoramiento de la vivienda y materiales de construcción. Vende una gama de materiales de construcción y productos de bricolaje y jardinería, además de prestar diversos servicios.” (Bloombergg, s/f-f) La empresa fue fundada en 1978 e ingreso en el DJIA en 1999. Opera en Estados Unidos, Canadá, China y México.

- **McDonald's**

McDonald's Corporation es una empresa que funciona a nivel internacional bajo el modelo de franquicias. Opera restaurantes de comida rápida donde sirven una variedad de menús económicos en países de todo el mundo. La empresa fue fundada en 1940 e ingreso en el DJIA en 1985. En la actualidad cuenta con más de 36.000 establecimientos. (Bloombergg, s/f-g)

- **Caterpillar Inc**

Caterpillar Inc. Es una compañía que diseña, produce y comercializa maquinaria de construcción, de minería y forestal. La empresa también produce motores y repuestos para sus productos y ofrece seguros y financiación. La empresa fue fundada en 1925 e ingreso al DJIA desde 1991. (Bloombergg, s/f-h)

- **IBM Corp**

International Business Machines Corporation, también conocido como IBM, ofrece soluciones computacionales con el uso de tecnología avanzada de información. En

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

su catálogo cuenta con el desarrollo de sistemas, servicios, software y computadores. Es uno de los pioneros en el mundo computacional. Fue fundada en el año 1911 e ingreso al DJIA desde 1999. (s/f-i)

- **Visa Inc**

“Visa Inc. opera una red minorista de pagos electrónicos y gestiona servicios financieros globales. Ofrece comercio global a través de la transferencia de valor e información entre instituciones financieras, comerciantes, consumidores, negocios y entidades de Estado.” (Bloombergg, s/f-j) Fue fundada en 1958 y pertenece al DJIA desde 2013

- **The Travelers Companies, Inc**

The Travelers Companies, Inc. provee soluciones de seguro a nivel comercial y privado. Sus servicios son dirigidos a negocios, unidades gubernamentales, asociaciones e individuales. La empresa fue fundada en 1853 y pertenece al DJIA desde 2009. (Bloombergg, s/f-k)

- **Chevron**

“Chevron Corporation es una empresa integrada de energía con operaciones alrededor del mundo. Extrae y transporta crudo y gas natural. También refina, comercia y distribuye carburantes, está involucrada en operaciones químicas, de minería, generación eléctrica y servicios de energía.” (Bloombergg, s/f-l) La empresa fue fundada en 1879 y pertenece al DJIA desde 2008

- **United Technologies Corporation**

United Technologies Corporation es una empresa que produce y comercializa motores de avión, ascensores, calentadores, aires acondicionados, equipo para helicópteros, sistemas de inyección de gasolina y equipo de seguridad contra incendios. La compañía fue fundada en 1934 e ingreso al DJIA desde 1939. (Bloombergg, s/f-m)

- **Johnson & Johnson**

Johnson & Johnson fabrica productos especializados en el cuidado personal y provee servicios relacionados en el uso de los mismos. Dentro de su catálogo se encuentran productos para la piel, para el cuidado del cabello y algunos medicamentos y material para hospitales. La empresa distribuye sus productos alrededor de todo el mundo. La empresa fue fundada en 1886 y pertenece al DJIA desde 1997. (Bloombergg, s/f-n)

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

- **JPMorgan Chase**

JPMorgan Chase & Co Es una banca de inversión que proporciona servicios financieros a nivel internacional. Dentro de sus servicios se encuentran la administración de activos, banca privada, financiación comercial y financiación bancaria. La empresa tiene dentro de sus clientes grandes corporaciones, instituciones gubernamentales e individuales con alto patrimonio. La empresa fue fundada en 1799 como “Bank of the Manhattan Company” y cambia su nombre al actual en el año 2000. Pertenece al DJIA desde 1991. (Bloombergg, s/f-o)

- **General Electric Company**

“General Electric Company es una empresa diversificada a nivel mundial de tecnología y servicios financieros. Ofrece productos y servicios como motores aeronáuticos, generación eléctrica, tratamiento de agua, electrodomésticos, imaginología médica, financiación de empresas y particulares, y productos industriales.” La empresa fue fundada en 1892 y pertenece al DJIA desde 1907. (Bloombergg, s/f-p)

- **American Express**

“American Express Company es una empresa mundial de pagos y viajes. Sus principales productos y servicios son de cobro y pago de tarjeta de crédito y servicios relacionados con viajes ofrecidos a clientes y empresas de todo el mundo.” La empresa fue fundada en 1850 y pertenece al DJIA desde 1982. (Bloombergg, q)

- **Walmart**

“Walmart Inc. opera tiendas de descuento, super centros y mercados de vecinos. Ofrece ropa, artículos para el hogar, aparatos pequeños, electrónica, instrumentos musicales, libros, bricolaje, calzado, joyas, artículos de niños pequeños, juegos, de primera necesidad, mascotas, farmacia, provisiones para fiestas y herramientas de autos.” (Bloombergg, s/f-r) Las tiendas Walmart se encuentran alrededor de todo el mundo. La empresa fue fundada en 1962 y pertenece al DJIA desde 1997 (Bloombergg, s/f-r)

- **Exxon Mobil**

“Exxon Mobil Corporation opera empresas petroleras y petroquímicas en todo el mundo. Sus operaciones incluyen la exploración y extracción de crudo y gas, generación eléctrica, carbón y minerales. También fabrica y comercia carburantes, lubricantes y químicos.” (Bloombergg, s/f-s) La empresa fue fundada en 1999 tras la fusión entre Exxon y Mobil y desde entonces pertenece al DJIA.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

- **Verizon**

“Verizon Communications Inc. es una empresa integrada de telecomunicaciones que provee servicios alámbricos de voz y datos, inalámbricos, de Internet e información de directorios publicados.” (Bloombergg, s/f-t) La empresa también le presta servicios de red a las organizaciones gubernamentales proporcionando líneas telefónicas de empresas, de datos, equipo de telecomunicaciones y teléfonos públicos. Verizon fue fundada en 1983 y pertenece al DJIA desde 2004. (Bloombergg, s/f-t)

- **NIKE**

“NIKE, Inc. diseña, desarrolla y comercia calzado, ropa, equipo y accesorios atléticos para hombres, mujeres y niños. Vende a nivel mundial a minoristas, tiendas propias, subsidiarias y distribuidores.” (Bloombergg, s/f-u). La empresa fue fundada en 1964 y pertenece al DJIA desde 2013.

- **Walt Disney**

The Walt Disney Company es una empresa de entretenimiento que produce programas de televisión, grabaciones musicales, libros y revistas principalmente dirigidos a la población juvenil y a niños. Adicionalmente cuenta con parques temáticos alrededor del mundo. La empresa fue fundada en 1923 y pertenece al DJIA desde 1991. (Bloombergg, s/f-v)

- **Microsoft**

Microsoft Corporation desarrolla, produce, licencia, venta y presta servicio de soporte de productos de software. Dentro de lo que ofrece la compañía se encuentran sistemas operativos, software de servidores, aplicaciones para negocios, software de internet y software de desarrollo. La empresa fue fundada en 1975 y pertenece al DJIA desde 1999. (Bloombergg, s/f-w)

- **Procter & Gamble**

The Procter & Gamble Company fabrica y comercializa productos de consumo en diferentes países alrededor del mundo. Dentro de su catálogo se encuentran productos de lavado y limpieza, papel higiénico, cuidado personal, y comida y bebidas del segmento de saludable. Los productos de la empresa son comercializados principalmente a través de tiendas minoristas y distribuidoras que operan a través del canal tradicional de ventas. Procter & Gamble products are sold primarily through mass merchandisers, grocery stores, membership club stores,

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

drug stores, and neighborhood stores. La empresa fue fundada en 1837 y se encuentra en el DJIA desde 1932. (Bloombergg, s/f-x)

- **DowDuPont Inc**

DowDuPont Inc. opera bajo el modelo de holding. La compañía, a través de sus subsidiarias, vende productos químicos desarrollados por estas mismas usados en diferentes sectores como la agricultura. DowDuPont surge como la fusión entre Dow Chemical y DuPont en 2017. Desde esta fecha se encuentra listada en el DJIA. (Bloombergg, s/f-y)

- **Merck & Co**

Merck & Co., Inc. es una empresa internacional especializada en el cuidado y áreas de la salud. Se encarga de ofrecer soluciones a través de la distribución de medicamentos prescritos, vacunas, terapias y productos de cuidado personal. Adicionalmente, la compañía tiene un segmento dedicado a productos especializados en el cuidado animal y su alimentación. Merck fue fundada en 1891 llevando más de 130 años de operación. Hace parte del DJIA desde 1979. (Bloombergg, s/f-z)

- **Intel**

Intel Corporation diseña, produce y vende componentes para computadores y sus productos relacionados. Su catálogo incluye microprocesadores, chipsets, microcontroladores, memorias flash, sistemas de administración de software y productos de imagen digital. La empresa fue fundada en 1968 y pertenece al DJIA desde 1999 (Bloombergg, s/f-aa)

- **Cisco Systems**

Cisco Systems, Inc diseña, produce y vende redes basadas en "Internet Protocol" IP y otros productos relacionados con tecnologías de información y comunicación (IT). Adicionalmente presta servicio y asistencia en los temas afines con el uso de estos productos. La empresa ofrece soluciones para la transferencia de datos, voz y video. Cisco opera a nivel internacional, fue fundada en 1984 y pertenece al DJIA desde 2009. (Bloombergg, s/f-ab)

- **The Coca-Cola Company**

"The Coca-Cola Company" produce, comercializa y distribuye bebidas refrescantes y syrups. La compañía distribuye sus productos a la mayoría de países a nivel

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

mundial, siendo la empresa de bebidas más grande del mundo. La compañía opera desde 1886 y pertenece al DJIA desde 1987. (Bloombergg, s/f-ac)

- **Pfizer Inc.**

Pfizer Inc. opera como una compañía farmacéutica. La empresa ofrece medicinas, vacunas, aparatos médicos, productos para el cuidado personal y productos médicos en general. Pfizer opera a nivel mundial, fue fundado en 1849 y pertenece al DJIA desde 2004. (Bloomberg, s/f-ad)

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

2. METODOLOGÍA

En este trabajo, los datos que se recolecten representan la principal herramienta para el desarrollo de los objetivos propuestos. Para esta recolección se hará uso del software de Bloomberg con el cual cuenta la universidad en el laboratorio financiero y software R Studio, el cual puede ser obtenido de forma gratuita en su página oficial.

Inicialmente, con el fin de delimitar el alcance del proyecto, se seleccionarán los activos que serán considerados por el software que se busca desarrollar. Por este motivo, se trabajará específicamente con los activos del Dow Jones Industrial Average de Estados Unidos. De este modo, en el resultado final, se esperará poder superar los retornos de este índice durante el periodo evaluado.

Para cumplir con los objetivos específicos propuestos, se realizarán las siguientes actividades de manera secuencial:

2.1 Analizar el comportamiento de los activos que componen el Dow Jones Industrial Average mediante series de tiempo teniendo en cuenta las tendencias y los cambios en la volatilidad.

En esta etapa inicial, se utilizó la plataforma de Bloomberg para la descarga de la información de los activos seleccionados. Los datos descargados corresponden a los precios de cierre diarios desde enero de 2010 hasta octubre de 2018 junto con sus volúmenes de negociación y su índice de fuerza relativa (RSI).

Una vez se obtuvieron los datos, se procedió a graficarlos de modo que se pudiera comparar el volumen, el comportamiento del precio del activo y su RSI. Esto se hizo con el fin de identificar posibles tendencias y relaciones entre las variaciones de los valores descargados.

Posteriormente, . Esto se hizo mediante los diagramas de autocorrelación parcial que se obtuvieron mediante el software R Studio. En el anexo 2 se puede observar el código utilizado para obtener estas gráficas.

2.2 Desarrollar un modelo neuronal para la estimación del comportamiento del precio y de la volatilidad de cada uno de los activos analizados para cada periodo.

Luego de hacer el análisis de las series de tiempo de los activos, se procedió a plantear un modelo neuronal que en primera instancia buscara explicar el

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

comportamiento de los precios. Para esto se utilizó una red Madaline donde las variables de entrada fueran el precio y el volumen rezagados ambos 4 periodos y el índice de fuerza relativa rezagado 1 periodo. Para el entrenamiento de la red se normalizaron las variables entre 1 y 2 utilizando el valor máximo y mínimo de cada serie de modo que se facilitara el entrenamiento de la red. La función utilizada para la normalización de los datos se describe a continuación:

$$f_n = \frac{f - \min(f)}{\max(f) - \min(f)} + 1$$

La razón por la cual se realizó una normalización entre 1 y 2 era para garantizar que los pronósticos obtenidos fueran positivos de modo que, al hacer una diferenciación logarítmica para obtener los retornos esperados, no se tuvieran valores negativos que arrojaran un error.

Con el fin de identificar si la varianza de estudiada presentaba fenómenos autorregresivos, una vez obtenidos los modelos neuronales que lograran ajustar el precio, se procedió a calcular la serie de errores del pronóstico de los retornos obtenidos. Esta serie se elevó al cuadrado y se calculó su diagrama de autocorrelación parcial para verificar si en efecto existía modelos autorregresivos que pudieran explicar la varianza.

Por último, se procedió a plantear una nueva red neuronal Madaline que buscará explicar los errores al cuadrado obtenidos utilizando 4 rezagos de estos. Se resalta que nuevamente se normalizaron los errores con la misma metodología.

Los modelos planteados fueron entrenados mediante el software Matlab y el código utilizado se encuentra en el anexo 1.

El entrenamiento de las series de tiempo se realizó para cada uno de los 30 activos del dow jones y el principal output que se buscaba era el pronóstico del retorno del activo para el día siguiente junto con su varianza esperada.

2.3 Desarrollar la estrategia de inversión propuesta mediante la integración de los modelos neuronales diseñados anteriormente

Teniendo los modelos desarrollados el objetivo número 2, será necesario el desarrollo de una herramienta que permita conformar el portafolio de inversión óptimo.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Se simuló en el software Metatrader, con el uso de simulink, el comportamiento de los activos pronosticados por los modelos con el comportamiento real. Luego de validar el aprendizaje satisfactorio de la red, se establecieron los criterios de compra y venta de cada uno de los activos de acuerdo con los pronósticos que se tenían en un periodo determinado. La estrategia consistía principalmente en comprar el activo cuando su pronóstico era positivo y cerrar la posición de este cuando el pronóstico era negativo. Se resalta que en el presente trabajo no se involucró en los modelos los costos de transacción y comisión y las variables de profundidad del mercado y “*slippage*”. El código que hace uso del componente simulink de Matlab se encuentra en el anexo 4.

La estrategia de inversión utilizada tampoco tiene en consideración las posiciones cortas pues busca superar el benchmark seleccionado únicamente haciendo uso de los incrementos en el mercado.

Teniendo los pronósticos de los precios, se procedió a encontrar los pronósticos de la varianza condicional de cada uno de los activos, haciendo uso de la red neuronal que explicaba el comportamiento de los errores al cuadrado. Todos estos datos se almacenaban en una tabla que registraba los pronósticos de todos los 30 activos evaluados.

Una vez obtenidos los pronósticos de los retornos, se realizó una separación entre los activos que tenían un pronóstico positivo y los que no. Los primeros fueron almacenados en una nueva tabla y con estos se procedió a conformar una matriz de varianzas y covarianzas con el fin de calcular el riesgo del portafolio que se busca formar. Para el cálculo de esta matriz se utilizó un modelo CCC (*Constant Conditional Correlation Matrix*) donde se utilizó la correlación entre los retornos de los precios de los activos y los pronósticos de las varianzas obtenidas. Esta matriz se obtiene de la multiplicación matricial:

$$CCC = diag(\sigma_i) * \rho_{ij} * diag(\sigma_i) \quad (18)$$

Donde $diag(\sigma_i)$ es una matriz cuadrada de nxn donde la diagonal esta compuesta por las varianzas pronosticadas de los activos y ρ_{ij} es la matriz de correlación obtenida de la muestra de los activos.

El modelo se desarrollo con intervalos de tiempo diarios por lo cual está diseñado para que este procedimiento se ejecute de manera diaria una vez cierra el mercado para saber cuales son los activos ideales que se deben comprar en la siguiente sesión.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Como la estrategia lo que busca estructurar es un portafolio que optimice la relación riesgo retorno, con la matriz CCC se puede obtener el cálculo del riesgo utilizando la siguiente ecuación:

$$\sigma^2_{portafolio} = W * CCC * W^T \quad (19)$$

Donde W es el vector de ponderación de los activos que componen el portafolio.

Para encontrar la composición óptima del portafolio, la herramienta se programó de modo que se pudiera optimizar la relación entre rentabilidad y volatilidad. Esta razón se expresa de la siguiente forma:

$$\frac{rt}{\sigma} = \frac{W * Rt}{\sqrt{W * CCC * W^T}} \quad (20)$$

Donde Rt es el vector de retornos esperados de los activos para t+1 y el denominador corresponde a la volatilidad esperada del portafolio.

Para optimizar esta relación, se debe optimizar la estructura del vector w que corresponde a las ponderaciones de compra de cada activo que tiene un pronóstico positivo para el día siguiente. Esta optimización se logro mediante un algoritmo repetitivo donde se generaban aleatorios 10 millones de veces y se seleccionaba la distribución de w que maximizaba la razón propuesta. El código para lograr esta optimización se encuentra en el anexo 3.

Esto se logra mediante el uso de algoritmos genéticos que obtengan los porcentajes a invertir en cada uno de los activos que se encuentran en señal de compra, teniendo en cuenta los pronósticos entregados y la matriz de varianzas y covarianzas obtenida por la herramienta desarrollada.

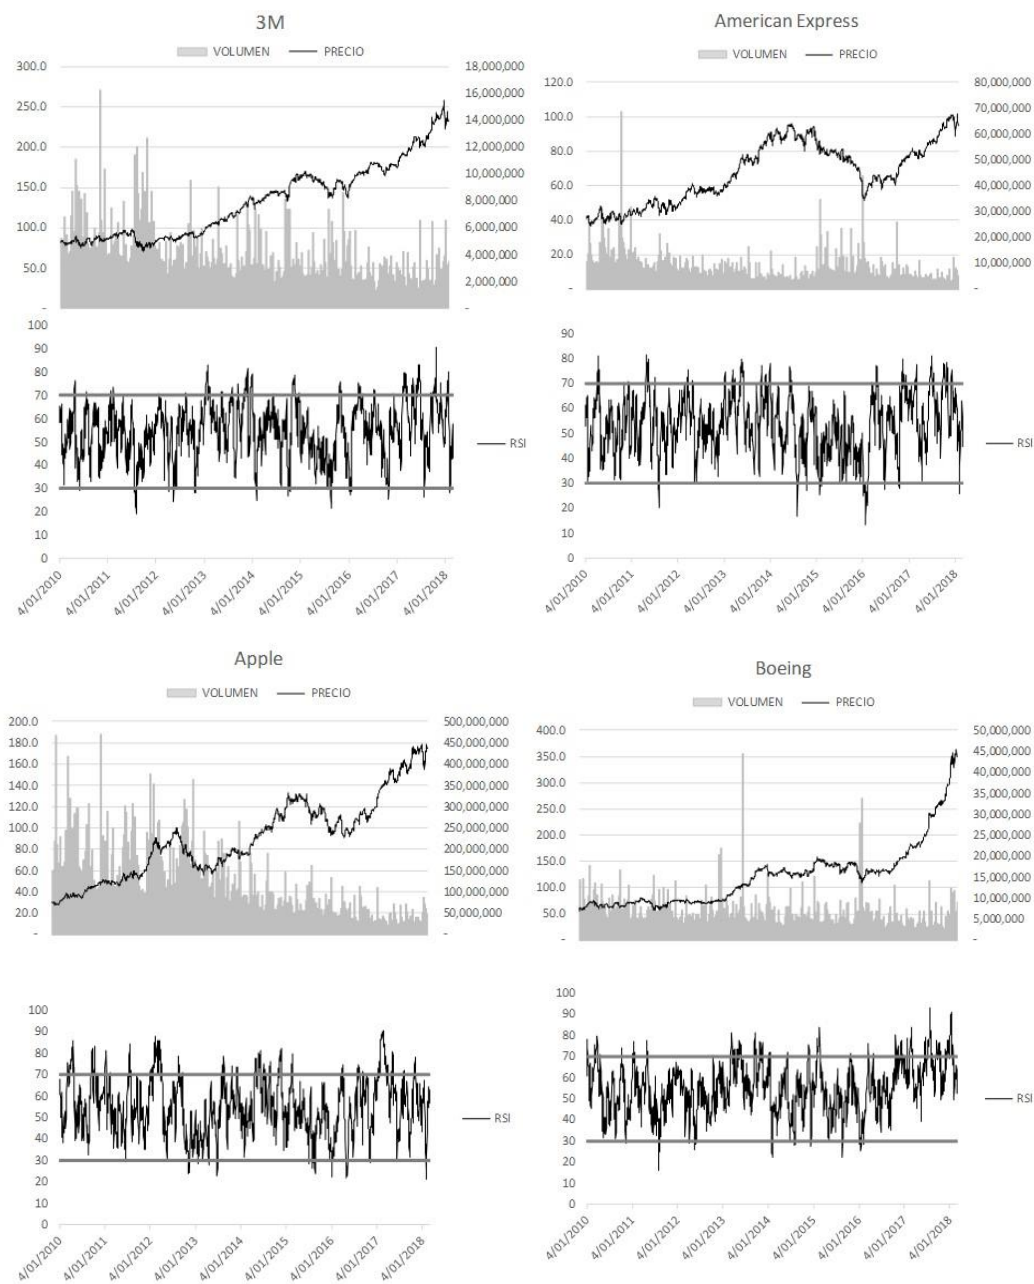
2.4 Validar el comportamiento de la estrategia de inversión de acuerdo con la conformación del portafolio y la ganancia a largo plazo.

Luego de programar la herramienta que permite optimizar la relación de rentabilidad riesgo, se realizó una validación en una ventana de tiempo de 500 días analizando diferentes periodos de modo que se pudiera comparar el retorno obtenido invirtiendo en un buy & hold directamente en el benchmark y el retorno obtenido utilizando las señales de compra y ventas arrojadas por la herramienta desarrollada. El código utilizado para este backtesting se encuentra en el Anexo 3.






La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

3. PRESENTACIÓN Y DISCUSIÓN DE RESULTADOS





3.1 Comportamiento de las series de precios.






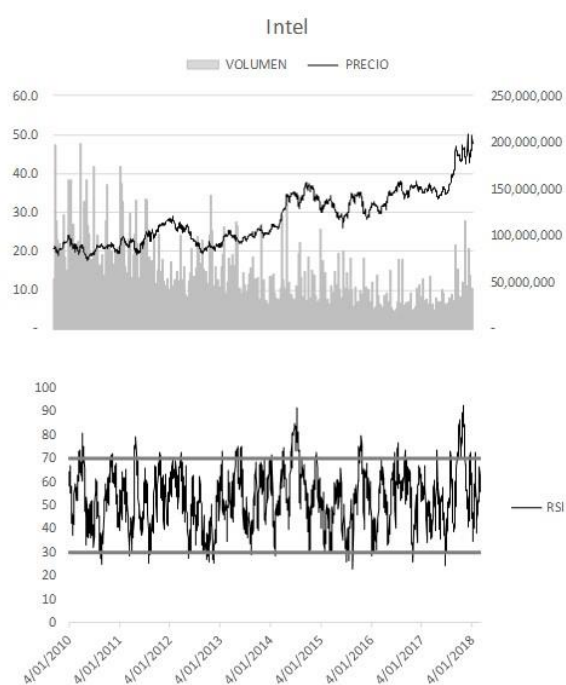
La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.







La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.







La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.







La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.




La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



En las series de precios observadas se encontró que la mayoría de los activos tienen una tendencia positiva en el largo plazo lo que es consistente con el comportamiento del PIB de Estados Unidos el cual ha mantenido un periodo de recuperación y crecimiento desde la crisis del 2008.

De igual manera, también se observa que la mayoría de los activos comparten los periodos de crecimiento y decrecimiento. Esto puede explicarse al considerar que todas las empresas evaluadas son pertenecientes al mercado de EEUU, por lo cual el rendimiento de la empresa va de la mano con la situación macroeconómica del país en cada periodo.

Sin embargo, se observa una correlación pequeña en el comportamiento de los precios lo que permite garantizar un portafolio diversificado al considerar diferentes sectores económicos.

Se observa también una correlación negativa entre el precio y el volumen negociado en todas las operaciones. Esto se puede explicar por la teoría de oferta y demanda donde una venta masiva del mismo título, incentiva una caída en su valor de mercado.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Por último, se observó que el indicador RSI permite entregar algunas señales en periodos de sobre compra y sobre venta que podrán ser tenidas en cuenta en el modelo neuronal.

La tabla 1 muestra el coeficiente de correlación encontrado entre el volumen con el precio y el RSI con el precio en cada uno de los activos analizados.

Acción	Volumen	RSI
3M	-48.54%	19.32%
American Express	-50.24%	13.48%
Apple	-64.04%	6.66%
Boeing	-20.39%	34.85%
Caterpillar	-27.11%	35.25%
Chevron	-56.10%	17.59%
Cisco Systems	-43.30%	34.13%
Coca-Cola	-40.50%	7.63%
DowDuPont	-21.01%	20.32%
ExxonMobil	-59.06%	16.54%
General Electric	-37.54%	7.71%
Goldman Sachs	-25.04%	22.53%
The Home Depot	-62.52%	8.19%
IBM	-23.64%	15.28%
Intel	-50.53%	22.57%
Johnson & Johnson	-48.23%	15.43%
JPMorgan Chase	-54.19%	28.15%
McDonalds	-34.96%	18.70%
Merck	-38.11%	8.25%
Microsoft	-49.72%	32.94%
Nike	-17.47%	-0.63%
Pfizer	-49.21%	8.77%
Procter & Gamble	-16.76%	13.15%
Travelers	-63.63%	12.91%
UnitedHealth Group	-53.28%	17.76%
United Technologies	-28.18%	15.16%
Verizon	-8.52%	6.28%
Visa	-42.98%	22.15%
Walmart	-36.42%	22.68%
Walt Disney	-29.24%	-0.16%

Tabla 1: Correlaciones Volumen, Precio y RSI

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

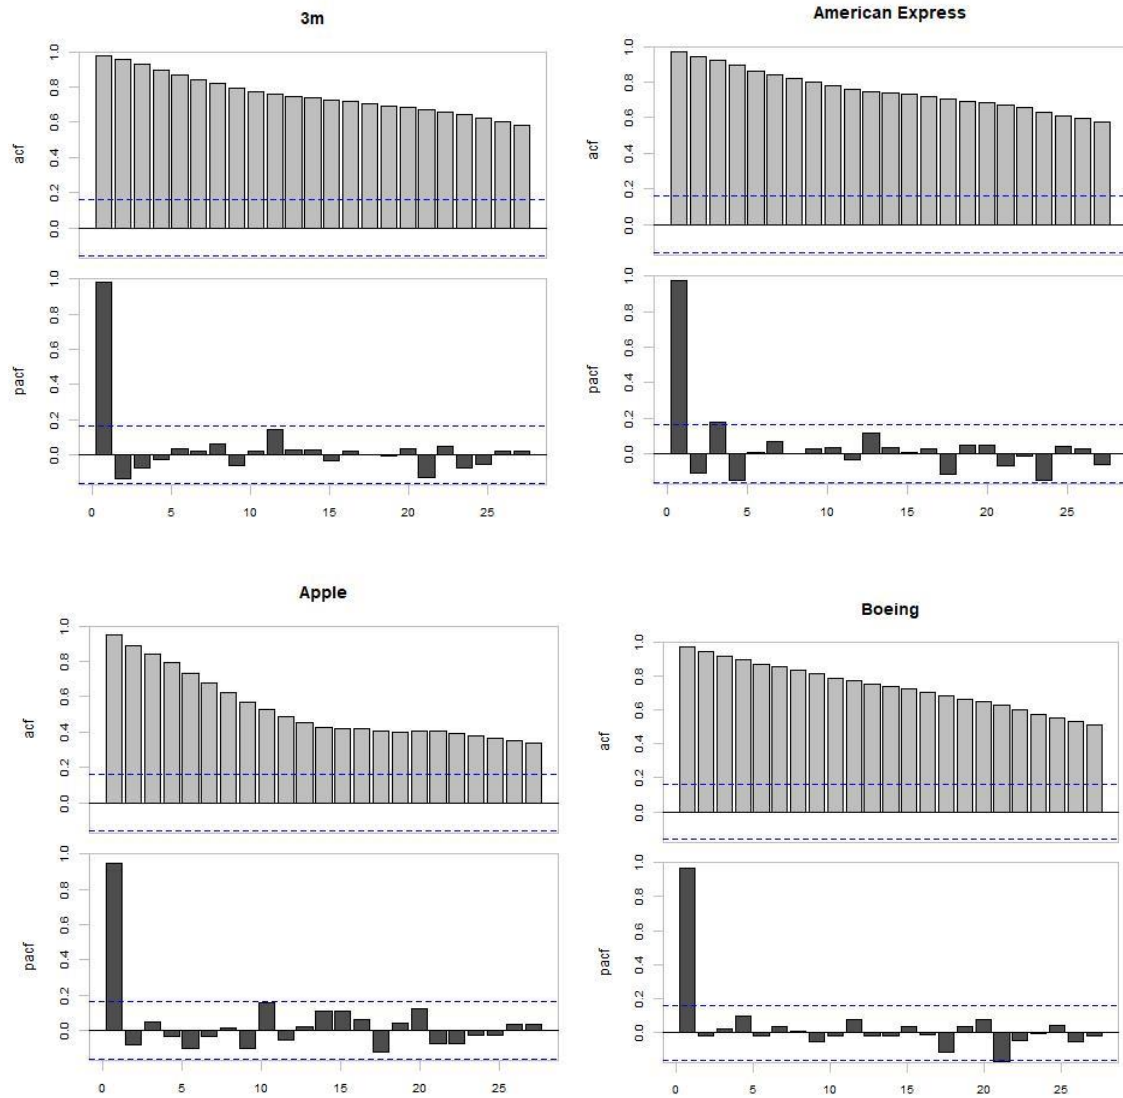
En la tabla 2 se encuentra la información resumida sobre el comportamiento de las series de tiempo de los activos analizados.

Empresa	Sector	Volumen diario negociado (USD)	Último precio USD	Retorno diario promedio	Desviación de los datos
3M	Conglomerado	2,820,741	212.75	-0.036%	1.16%
American Express	Financiero	5,848,683	107.55	-0.033%	1.46%
Apple	Electrónicos	81,143,418	228.01	-0.079%	1.59%
Boeing	Aeroespacial	4,606,799	381.35	-0.074%	1.51%
Caterpillar	Construcción	6,289,160	153.74	-0.029%	1.68%
Chevron	Petróleo y Gas	7,531,000	125.36	-0.012%	1.33%
Cisco Systems	Computacional	37,937,253	48.84	-0.019%	1.59%
Coca-Cola	Bebidas	15,042,319	46.27	-0.018%	0.92%
DowDuPont	Químicos	8,726,325	65.25	-0.018%	1.81%
ExxonMobil	Petróleo y Gas	15,414,077	85.84	-0.003%	1.16%
General Electric	Conglomerado	50,510,938	12.12	0.022%	1.44%
Goldman Sachs	Servicios Financieros	4,728,011	225.98	0.002%	1.65%
The Home Depot	Mejoras domésticas	7,839,114	207.76	-0.082%	1.24%
IBM	Computadores	4,725,119	153.60	0.000%	1.20%
Intel	Semiconductores	38,857,188	47.93	-0.027%	1.50%
Johnson & Johnson	Farmacéutica	9,127,339	140.09	-0.032%	0.90%
JPMorgan Chase	Banco	23,652,741	113.53	-0.030%	1.62%
McDonalds	Comidas Rápidas	5,512,711	166.08	-0.040%	0.97%
Merck	Farmacéutica	12,583,984	71.67	-0.022%	1.21%
Microsoft	Software	41,632,087	114.85	-0.050%	1.41%
Nike	Moda	9,316,425	84.15	-0.063%	1.46%
Pfizer	Farmacéutica	33,847,144	44.36	-0.033%	1.14%
Procter & Gamble	Bienes de consumo	9,696,621	83.88	-0.010%	0.90%
Travelers	Seguros	2,507,569	128.83	-0.038%	1.12%
UnitedHealth Group	Cuidado Personal	5,324,125	269.01	-0.088%	1.41%
United Technologies	Conglomerado	4,074,861	141.42	-0.024%	1.21%
Verizon	Telecomunicaciones	16,193,623	53.83	-0.019%	1.07%
Visa	Financiero	13,671,016	149.52	-0.077%	1.48%
Walmart	Retail	9,437,943	95.35	-0.020%	1.10%
Walt Disney	Entretenimiento	8,798,669	115.61	-0.050%	1.31%

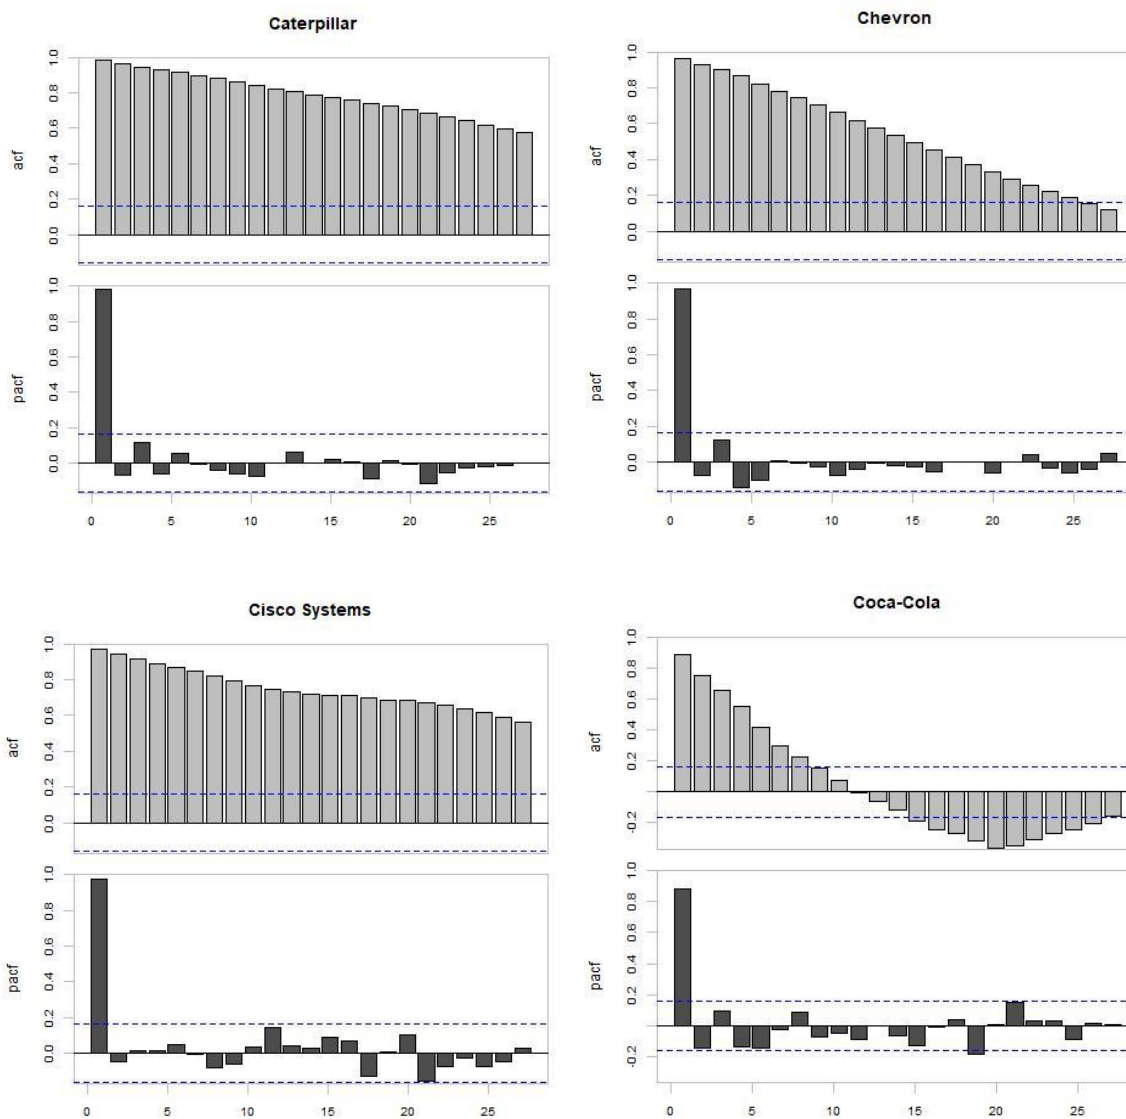
Tabla 2: Resumen de la información de las series de tiempo

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

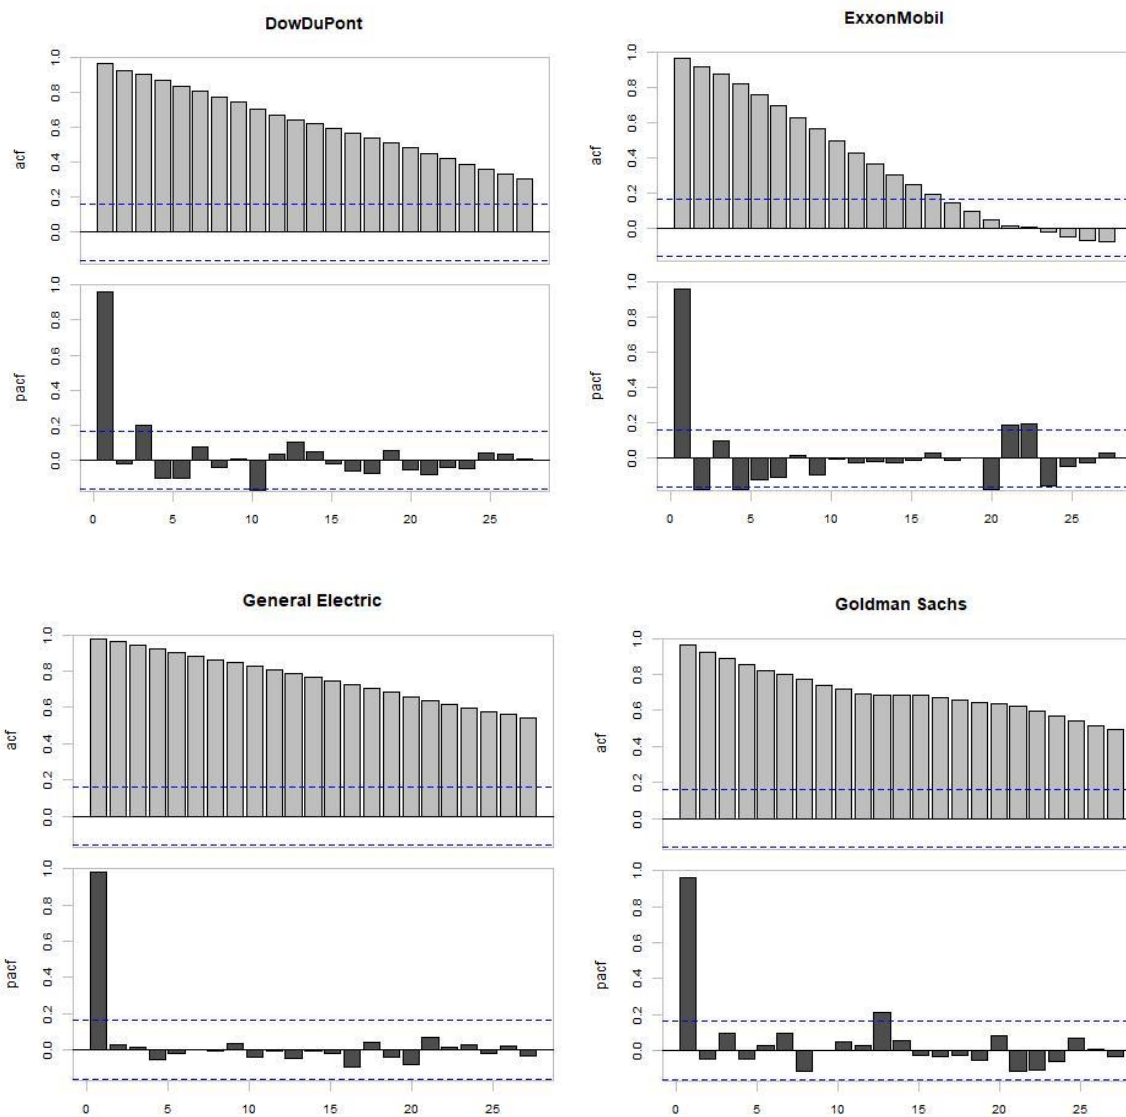
3.2 Análisis de autocorrelación de las series de precios.



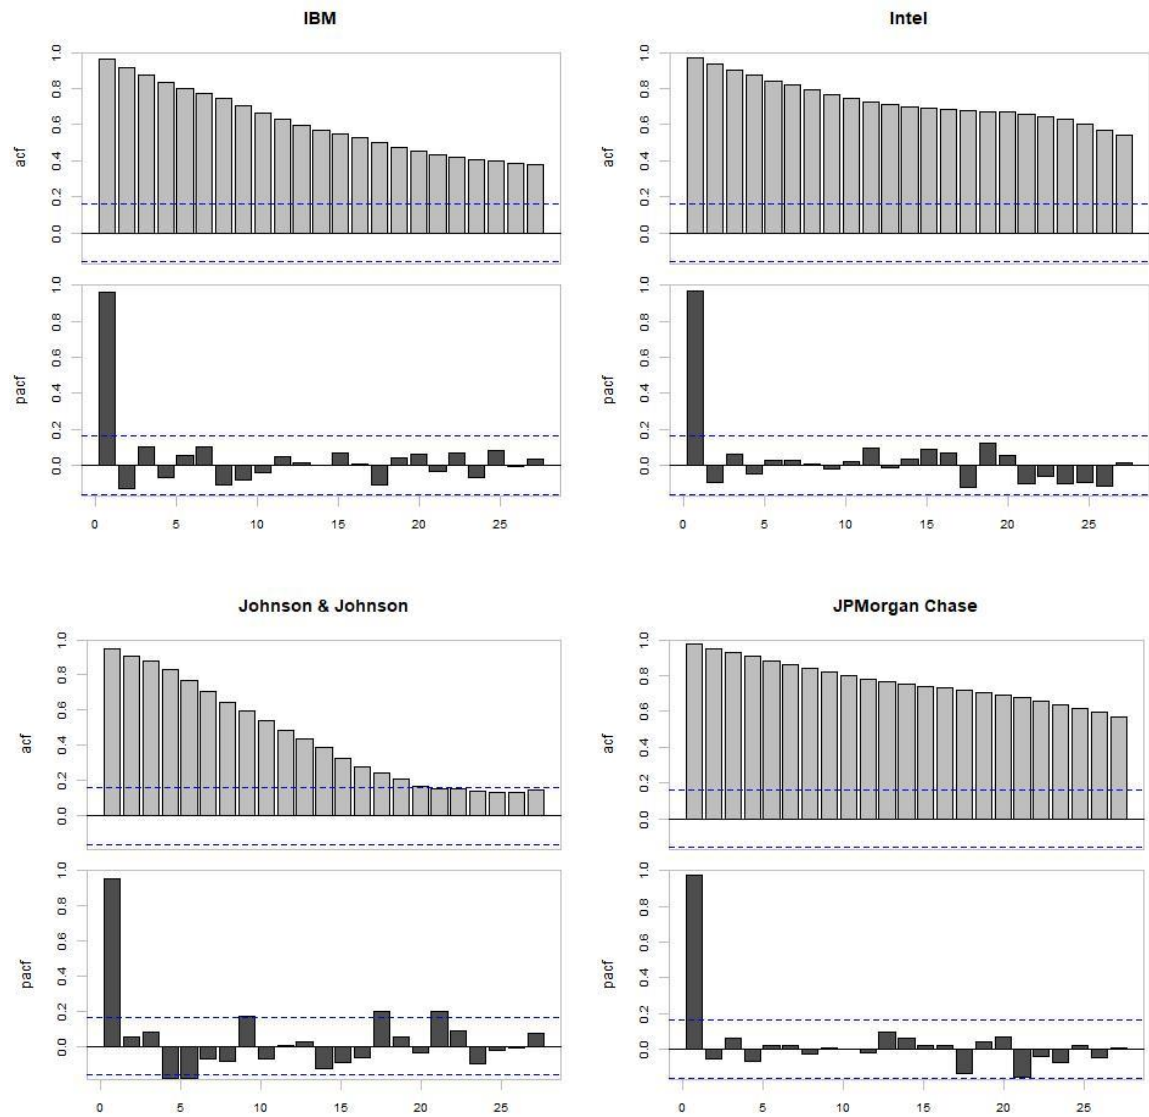
La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



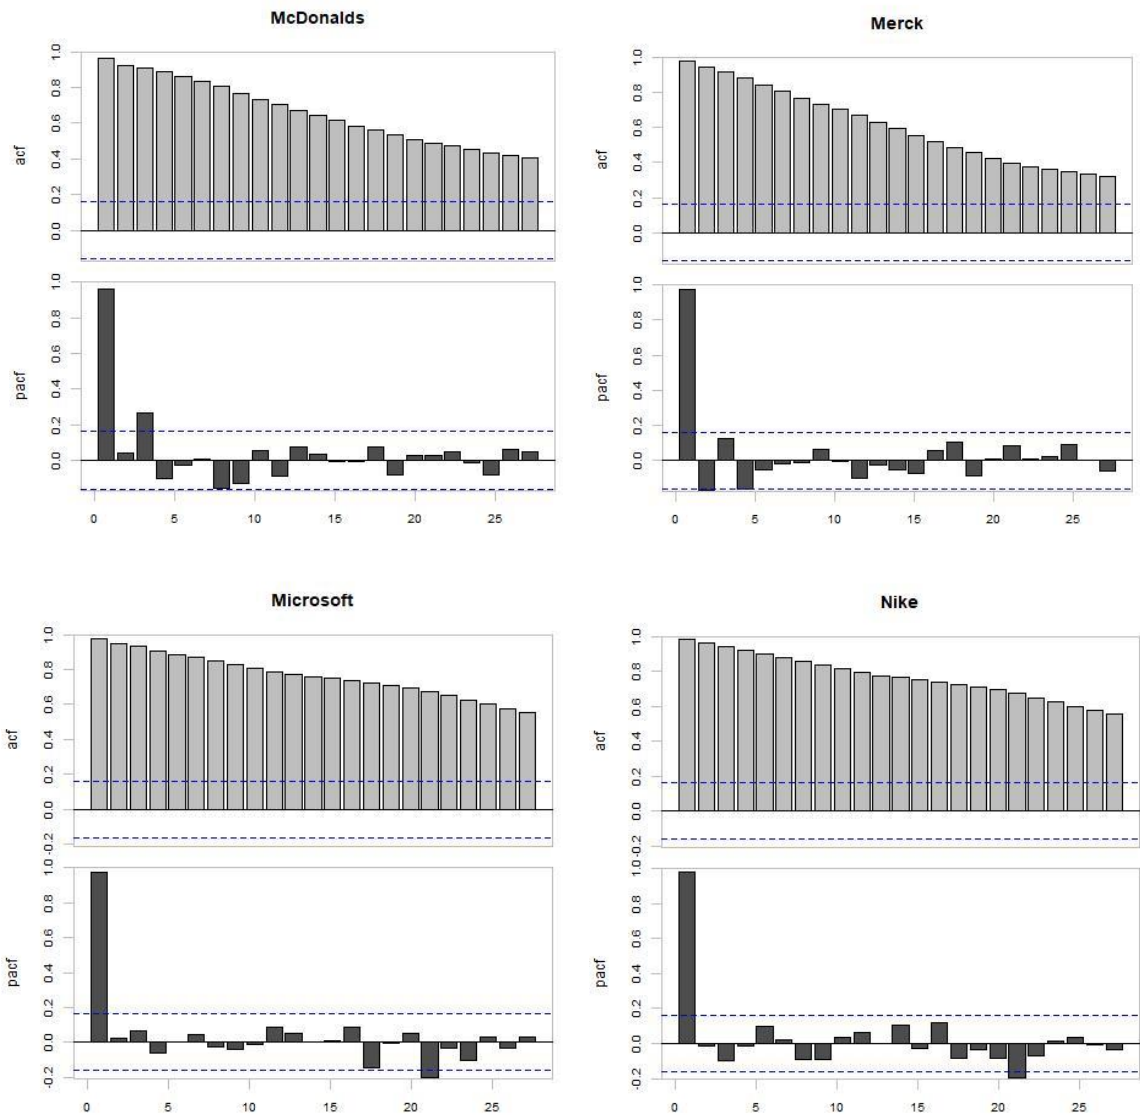
La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



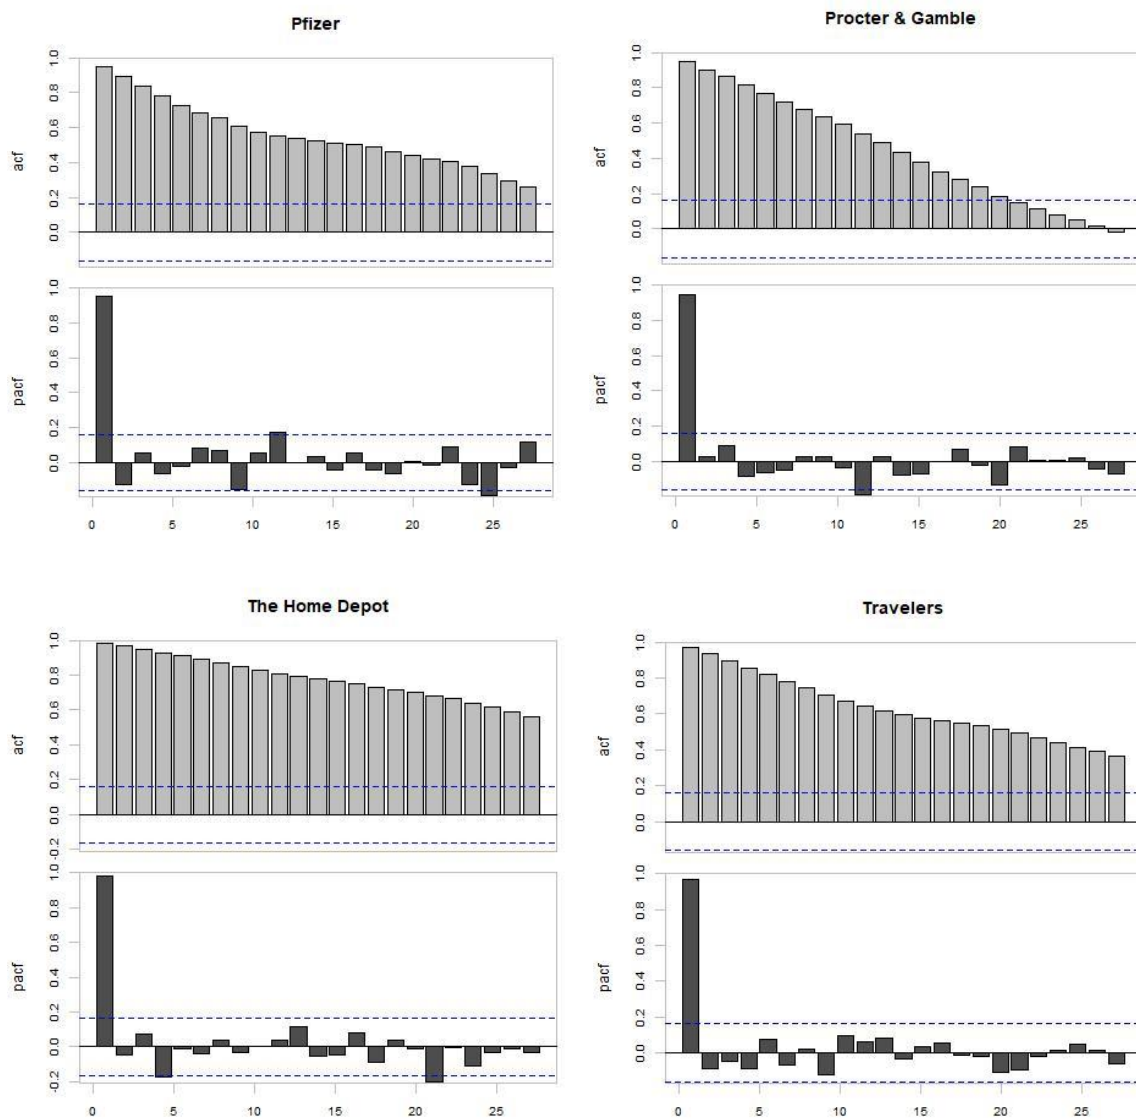
La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



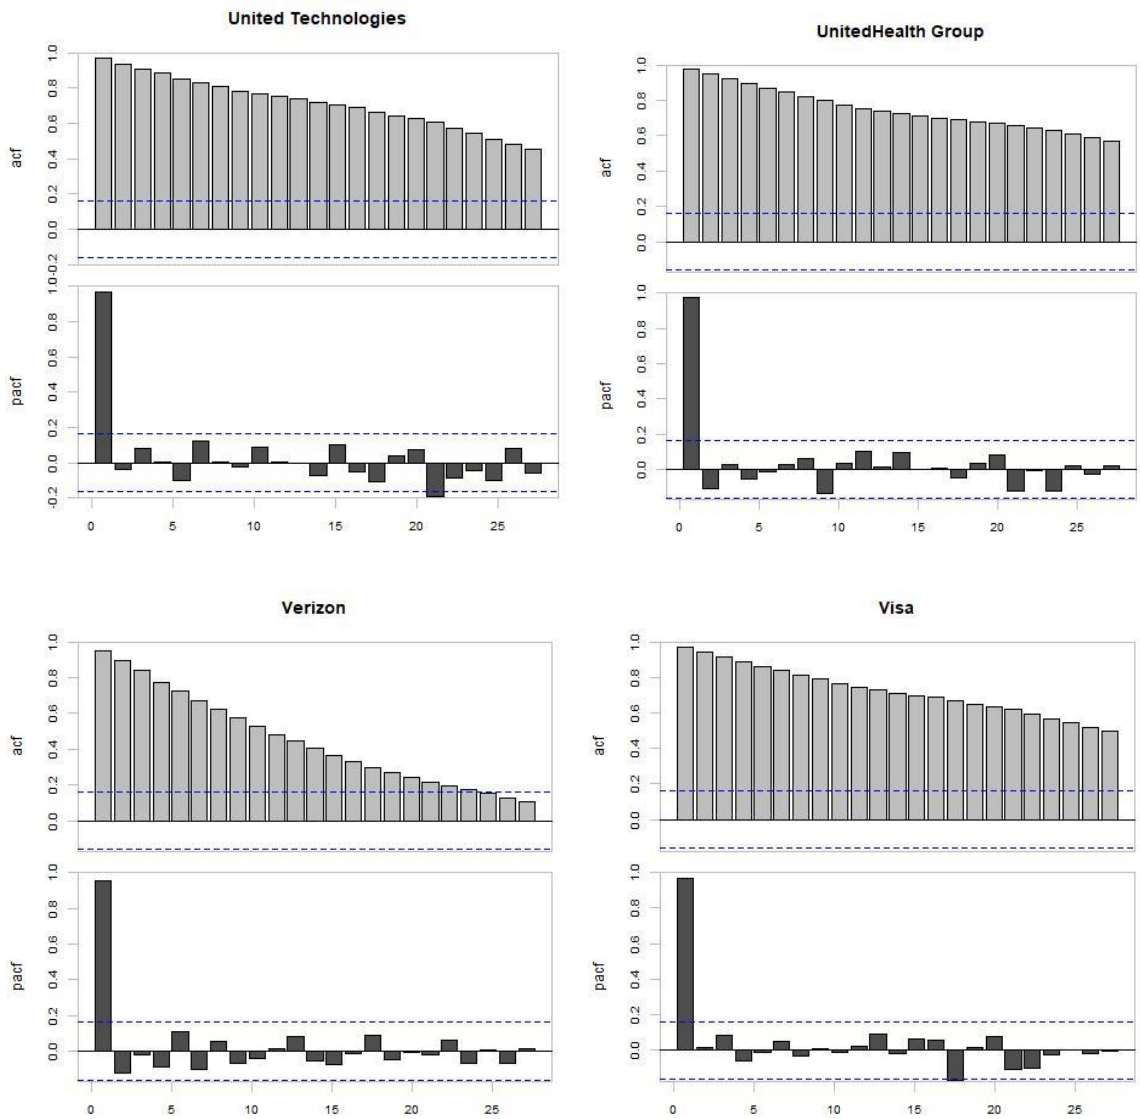
La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



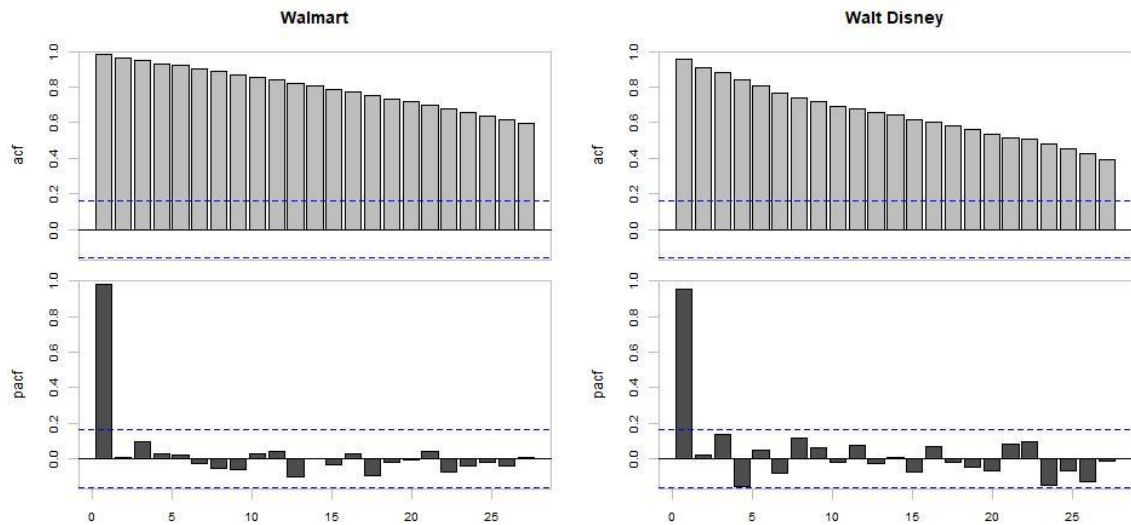
La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

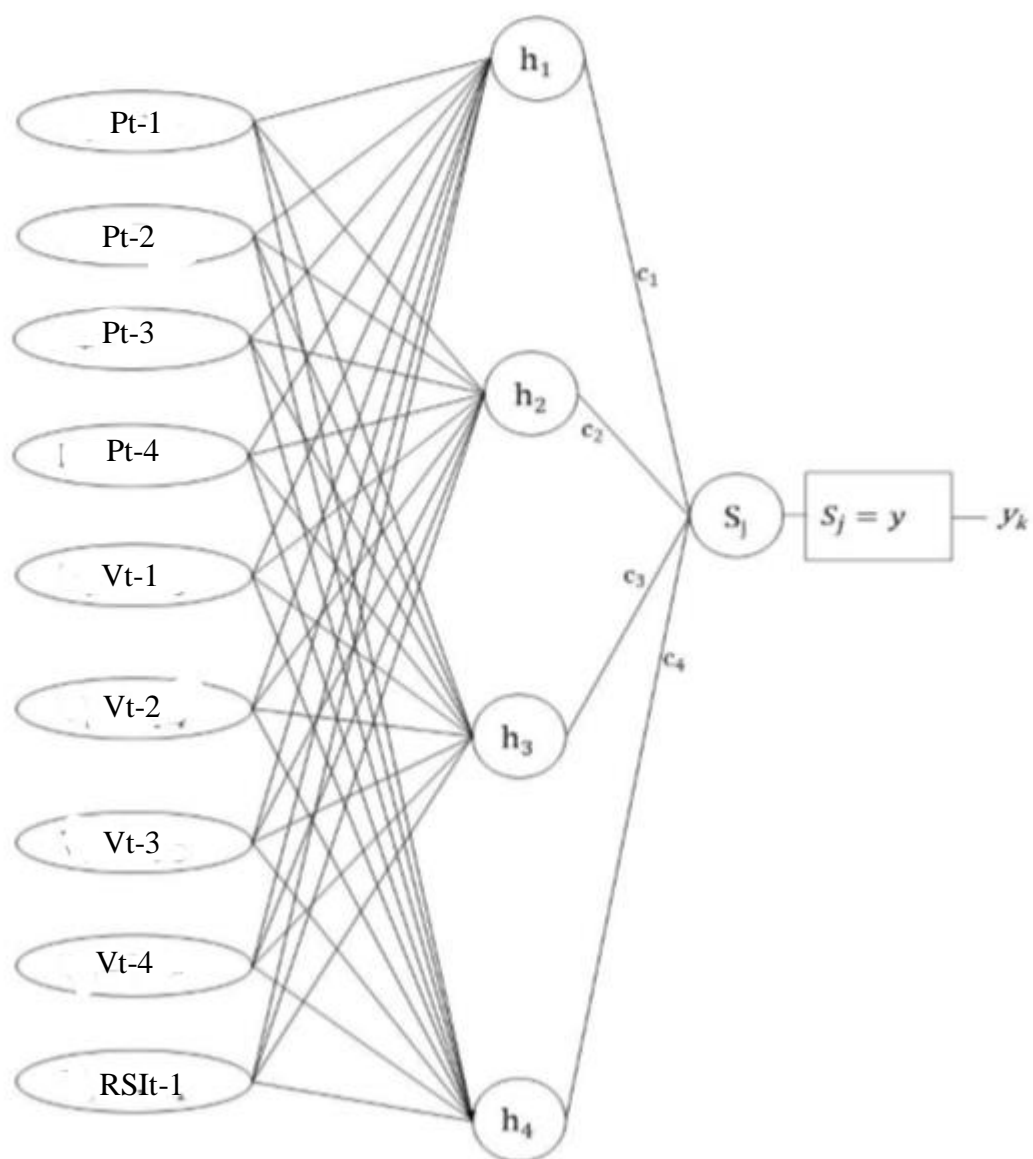


En todas las gráficas de autocorrelación se puede concluir que las series de precios de los activos son autorregresivos. Esto se debe a la forma de la gráfica en la cual parte de uno y decae lentamente.

En cuanto al número de rezagos que se seleccionarán para entrenar los modelos, se observa que, en el gráfico de autocorrelación parcial, se observa significancia en la mayoría de los activos en el primer rezago y eventualmente en los 4 primeros rezagos. Por este motivo en el modelo seleccionado serán tenidos en cuenta 4 rezagos de la serie de precios, de la serie de volumen y del RSI.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

3.3 Estructura de la red neuronal



La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Adicionalmente, las ecuaciones de actualización de los pesos y el cálculo del error fueron las siguientes:

$$\cdot c_j = c_j + \alpha * e_k * h_j$$

$$\cdot w_{ij} = w_{ij} + e_k * \alpha * c_j * X_{ij}$$

$$\cdot e_k^2 = \frac{1}{2}(y_{deseado} - y_k)^2$$

$$\cdot h_j = w_{ij} \cdot X_i$$


$$\cdot y_k = c_j \cdot h_j$$

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.


3.4 Resultados del modelo neuronal en la predicción de precios.

La red neuronal que se utilizó en el modelo fue entrenada en Matlab con el uso de la herramienta simulink. En el anexo 4 se encuentra el código de la red junto con la estructura de esta. Los resultados obtenidos para cada uno de los activos se muestran a continuación. Las líneas azules muestran el comportamiento de la serie de tiempo y las amarillas el ajuste de la red neuronal.


- **3M**



- **American Express**




- **Apple**




- **Boeing**


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.




- **Caterpillar**



- **Chevron**




- **Cisco Systems**




La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.


- **Coca-Cola**




- **DowDuPont**



- **ExxonMobil**




- **General Electric**




La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.


- **Goldman Sachs**



- **IBM**




- **Intel**




- **Johnson & Johnson**


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.




- **JPMorgan Chase**



- **McDonalds**




- **Merck**




La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.


- **Microsoft**



- **Nike**




- **Pfizer**




- **Procter & Gamble**


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.




- **The Home Depot**



- **Travelers**




- **United Technologies**




- **UnitedHealth Group**


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.




- **Verizon**



- **Visa**




- **Walmart**



La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

- **Walt Disney**



En los gráficos se observa como la red neuronal logró obtener un ajuste significativo a la serie de precios. La tabla 3 muestra el error cuadrático medio de cada ajuste realizado.


Accion	Error cuadrático medio
3M	0.0399
American Express	0.0060
Apple	0.0034
Boeing	0.0290
Caterpillar	0.0316
Chevron	0.0231
Cisco Systems	0.0281
Coca-Cola	0.1654
DowDuPont	0.0116
ExxonMobil	0.0251
General Electric	0.0398
Goldman Sachs	0.0573
The Home Depot	0.0105
IBM	0.0378
Intel	0.0525
Johnson & Johnson	0.0573
JPMorgan Chase	0.0206
McDonalds	0.0158
Merck	0.0182
Microsoft	0.0040
Nike	0.0879
Pfizer	0.0019
Procter & Gamble	0.0185
Travelers	0.0015
UnitedHealth Group	0.0097
United Technologies	0.0322
Verizon	0.0133
Visa	0.0234
Walmart	0.0064
Walt Disney	0.0138

Tabla 3: Error cuadrático medio


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

3.5 Resultados de Backtesting para diferentes franjas de tiempo

3.5.1 Periodos Semestrales




En el periodo comprendido entre enero y junio de 2018 se evidenció que la estrategia tuvo un comportamiento que superó significativamente al DJIA. Para el caso de la estrategia, esta tuvo un rendimiento del 2.4% mientras que para el mismo periodo el DJIA presentó desvalorizaciones del 2.2%.



La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.


Para el periodo comprendido entre julio y diciembre de 2017, se evidenció que el benchmark superó los movimientos ejecutados con la estrategia obteniendo el primero un rendimiento de 15.1% mientras que el segundo 7.7%. Sin embargo se resalta el movimiento positivo que tuvieron ambas posiciones.




En el primer semestre de 2017 también se evidencia que el benchmark tuvo un mejor rendimiento que la estrategia siendo el primero de 7.1% y el segundo de 4.6% nuevamente se resalta que ambos retornos fueron positivos.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

3.5.2 Periodos Anuales




Durante lo transcurrido del 2018 hasta el mes de septiembre, se observa un comportamiento muy homogéneo entre los rendimientos alcanzados por la estrategia y los alcanzados por el benchmark. Sin embargo, a cierre de mes la estrategia presenta un retorno superior al del benchmark siendo los valores de los retornos 8% y 6.6% respectivamente. La estrategia superó al benchmark en un 1.4%.




La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Para el año 2017, se observa que la estrategia fue superada significativamente por el benchmark. La estrategia tuvo un retorno 13.1% y el benchmark 24% siendo este un retorno casi igual a doble del primero.


3.5.3 Periodos Trimestrales



Para el tercer trimestre de 2018, la estrategia fu superada por el índice en 3.3 puntos porcentuales. Sin embargo, nuevamente se observa que en ambos casos las dos posiciones presentan retornos positivos al cierre del periodo.





En el segundo trimestre del 2018, la estrategia logra superar el índice en 1.9 puntos porcentuales. Ambas posiciones presentan retornos positivos



En el primer trimestre del 2018 se observa que la estrategia logra tener un retorno positivo del 1.4%. Por otro lado, el índice tiene una desvalorización de 2.9%

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.




Para los trimestres 3 y 4 de 2017 la estrategia no pudo superar al índice siendo superada en 4.8% y 1.6% respectivamente por el mismo. Sin embargo se mantiene el hecho de que en ambos casos se tienen retornos positivos en todas las posiciones analizadas.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.




El segundo trimestre de 2017 fue bastante mixto, evidenciándose franjas de tiempo en que la estrategia superaba al índice y viceversa. Sin embargo, al cierre del periodo, el índice obtiene un retorno del 3.4% y la estrategia del 3.9%, siendo esta última la que arroja un mayor retorno



En el primer trimestre de 2017 la estrategia supera al índice en 1.9 puntos porcentuales. Se mantiene el hecho de que ambas posiciones arrojan rendimientos positivos.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



Para el cuarto trimestre de 2016, se observa movimientos bruscos en el índice mientras que la estrategia presenta un comportamiento mas suavizado. Al cierre del periodo la estrategia es superada por el índice en un punto porcentual pero se resalta que además de que ambas posiciones cierran positivas, la estrategia supero al índice en la mayor parte del periodo evaluado siendo esta superada solo en el último mes.

3.5.4 Análisis comparativo adicional

En total se realizo un seguimiento de la estrategia vs el índice durante 499 días. Agrupando los resultados se evidencian lo siguiente:

La herramienta tuvo rendimientos positivos en 287 días y negativos en 212 días. El promedio de los rendimientos positivos diarios fue de 0.44% y el promedio de los rendimientos negativos fue de 0.45%.

El índice tuvo rendimientos positivos en 285 días (2 días menos que la estrategia) y tuvo un promedio de rendimientos positivos de 0.47% y negativos de 0.44%.

La estrategia superó en 268 días los rendimientos arrojados por el índice. En promedio, los días en que la estrategia superaba al índice, lo hacía en 27 puntos básicos. Por otro lado, en promedio, los días que el índice superaba a la estrategia, lo hacía en 28 puntos básicos.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

4. CONCLUSIONES Y CONSIDERACIONES FINALES

En el trabajo se logró desarrollar un modelo neuronal adaptativo que permitiera ajustarse al comportamiento de las series de precios de los activos analizados. La estrategia planteada permite actualizar de manera automática la composición ideal del portafolio de inversión tratado en la frecuencia de tiempo en que se introduzcan los inputs. Esta composición se da con base en la optimización de la relación rentabilidad riesgo la cual se obtiene tras pronosticar los retornos esperados y la volatilidad condicional de los activos.

Se resalta que el alcance de este trabajo se limitó a analizar las 30 acciones que componen el DJIA y a estructurar un portafolio que tuviera en cuenta estas acciones. En el backtesting realizado, se obtuvieron resultados mixtos que no permiten garantizar la efectividad de la estrategia desarrollada en un periodo de tiempo determinado. Pese a que la estrategia arrojó un rendimiento positivo en el 100% de los casos analizados, al compararla con el índice DJIA, se observó que no siempre se lograba superar los rendimientos que se obtenían realizando una inversión “Buy & Hold” sobre el mismo. Por el contrario, se observó que en aproximadamente el 45% de los casos el índice superaba la estrategia y que en una inversión sostenida en el largo plazo tanto para periodos de tiempo de 3 meses, 6 meses y un año, esta razón se mantenía.

Aunque los retornos obtenidos en el periodo analizado son todos positivos, no se puede garantizar que la estrategia será positiva siempre pues se evaluó un periodo de tiempo donde la economía fue principalmente expansiva y con un mercado accionario alcista. Sin embargo, lo que si se resalta es que la estrategia logra suavizar las fluctuaciones que tiene el mercado producto de la optimización de la relación de riesgo y rentabilidad.

Para el futuro se recomendaría analizar la efectividad de la estrategia en periodos de tiempo donde se tenga una economía contractiva como es el caso del 2008 y que se trate de agrupar ciclos económicos completos en har  de evaluar de manera integral el comportamiento de la estrategia. Adicionalmente se podr a evaluar la efectividad de esta en otros  ndices globales y de otros sectores de la econom a para llegar a una generalizaci n de la efectividad real que tiene el modelo de inversi n propuesto.

Por  ltimo, como el ejercicio realizado fue acad mico, si se quiere realizar una simulaci n aplicada a la vida real para obtener las ventajas reales que puede tener la estrategia planteada sobre la inversi n directa en los  ndices que se repliquen, se recomienda tener en cuenta el efecto que tiene el slippage, los costos de transacci n y comisi n y la profundidad del mercado que se esta evaluando. Estas

La informaci n presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

variables pueden afectar significativamente los precios de entrada y salida que se tienen en el mercado en cada posición tomada y por ende altera la rentabilidad real obtenida.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

REFERENCIAS

- Ailon, G. (2012). The Discursive Management of Financial Risk Scandals: The Case of Wall Street Journal Commentaries on LTCM and Enron. *Qualitative Sociology*, 35(3), 251-270. doi:10.1007/s11133-012-9217-5
- Alzghool, R. (2017). Parameters estimation for GARCH (p,q) model: QL and AQL approaches. *Electronic Journal Of Applied Statistical Analysis*, 10(1), 180-193. doi:10.1285/i20705948v10n1p180
- Berutich, J. M., López, F., Luna, F., & Quintana, D. (2016). Robust technical trading strategies using GP for algorithmic portfolio selection. *Expert Systems With Applications*, 46307-315. doi:10.1016/j.eswa.2015.10.040
- Bloomberg Platafotm (sf-a). DJIA Index Description, perfil de Boeing. Recuperado el 30 de junio de 2018
- Bloomberg Platafotm (sf-b). DJIA Index Description, perfil de UnitedHealth Group. Recuperado el 30 de junio de 2018
- Bloomberg Platafotm (sf-c). DJIA Index Description, perfil de Goldman Sachs. Recuperado el 30 de junio de 2018
- Bloomberg Platafotm (sf-d). DJIA Index Description, perfil de 3M. Recuperado el 30 de junio de 2018
- Bloomberg Platafotm (sf-e). DJIA Index Description, perfil de Apple. Recuperado el 30 de junio de 2018
- Bloomberg Platafotm (sf-f). DJIA Index Description, perfil de The Home Depot. Recuperado el 30 de junio de 2018
- Bloomberg Platafotm (sf-g). DJIA Index Description, perfil de McDonalds. Recuperado el 30 de junio de 2018
- Bloomberg Platafotm (sf-h). DJIA Index Description, perfil de Caterpillar. Recuperado el 30 de junio de 2018
- Bloomberg Platafotm (sf-i). DJIA Index Description, perfil de IBM. Recuperado el 30 de junio de 2018
- Bloomberg Platafotm (sf-j). DJIA Index Description, perfil de Visa. Recuperado el 30 de junio de 2018

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Bloomberg Platafotm (sf-k). DJIA Index Description, perfil de Travelers. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-l). DJIA Index Description, perfil de Chevron. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-m). DJIA Index Description, perfil de United Technologies. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-n). DJIA Index Description, perfil de Johnson & Johnson. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-o). DJIA Index Description, perfil de JPMorgan Chase. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-p). DJIA Index Description, perfil de General Electric. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-q). DJIA Index Description, perfil de American Express. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-r). DJIA Index Description, perfil de Walmart. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-s). DJIA Index Description, perfil de ExxonMobil. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-t). DJIA Index Description, perfil de Verizon. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-u). DJIA Index Description, perfil de Nike. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-v). DJIA Index Description, perfil de Walt Disney. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-w). DJIA Index Description, perfil de Microsoft. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-x). DJIA Index Description, perfil de Procter & Gamble. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-y). DJIA Index Description, perfil de DowDuPont. Recuperado el 30 de junio de 2018

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Bloomberg Platafotm (sf-z). DJIA Index Description, perfil de Merck. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-aa). DJIA Index Description, perfil de Intel. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-ab). DJIA Index Description, perfil de Cisco Systems. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-ac). DJIA Index Description, perfil de Coca-Cola. Recuperado el 30 de junio de 2018

Bloomberg Platafotm (sf-ad). DJIA Index Description, perfil de Pfizer. Recuperado el 30 de junio de 2018.

Bodie, Z., Kane, A., & Marcus, A. J. (2004). Principios de inversiones (Quinta edi).

Dip, J., Romero, P. (2015). Una comparación de redes neuronales y modelos Arch-Garch para predecir variaciones en el precio de acciones. Aplicación a un caso de acciones de telefonía. Revista de investigación en modelos financieros. (2015 - II) vol. 2

Giraldo, N. (2006). Notas de Clase Series de Tiempo con R. Universidad Nacional de Colombia.

Grigoriu, A (2011). Volatility as a risk measure. Active asset allocation. Recuperado de : <http://active-asset-allocation.com/wp-content/uploads/2018/04/Risk-Letter-1-Version-ENG.pdf>

Gujarati, Damodar N., Econometría básica, tercera edición, MacGraw-Hill, Colombia, 1997.

Isasi Viñuela, P. and Galván León, I. (2004). Redes de neuronas artificiales. 1st ed. Madrid: Pearson Educación.

Jorion, P. (2011). Financial risk manager handbook plus test bank. 1st ed. Hoboken, N.J: John Wiley.

Arneric, J., Polkepovic, T., Alijnovic, Z. (2014) . GARCH based artificial neural networks in forecasting conditional variance of stock returns. Croatian Operational Research Review. 329-343

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

- Kia, F., Jeney, G., & Levendovszky, J. (2014). Loss-minimal Algorithmic Trading Based on Levy Processes. *TEM Journal*, 3(3), 210-215.
- Montero, R. (2013). Variables no estacionarias y cointegración. Documentos de Trabajo En Economía Aplicada. Universidad de Granada, España, 1–8. Retrieved from <http://www.ugr.es/~montero/matematicas/cointegracion.pdf>
- Rossi, E. (2010). Multivariate GARCH Models. *Econometría Financiera*, 2010. Recuperado de http://economia.unipv.it/pagp/pagine_personali/erossi/rossi_multivariate_garch_Ecnmtra_Fin_2010.pdf el 30 de septiembre de 2018.
- Serrano Cadiz, A (2011). Optimización estocástica mediante métodos de Monte Carlo. Recuperado de <http://hdl.handle.net/10016/12096> el 30 de septiembre de 2018
- Shen, J. (2015). A Pre-Trade Algorithmic Trading Model Under Given Volume Measures and Generic Price Dynamics. *Applied Mathematics Research Express*, 2015(1), 64-98.
- Treleaven, P., Galas, M., & Lalchand, V. (2013). Algorithmic Trading Review. *Communications Of The ACM*, 56(11), 76-85. doi:10.1145/2500117
- Williams, J. W., & Cook, N. M. (2016). Econometrics as evidence? Examining the 'causal' connections between financial speculation and commodities prices. *Social Studies Of Science* (Sage Publications, Ltd.), 46(5), 701-724. doi:10.1177/0306312716658980
- Yadav, Y. (2015). How Algorithmic Trading Undermines Efficiency in Capital Markets. *Vanderbilt Law Review*, 68(6), 1607-1671.
- Ying, L., & Ya-Nan, L. (2017). A Parametric Sharpe Ratio Optimization Approach for Fuzzy Portfolio Selection Problem. *Mathematical Problems In Engineering*, 1-17. doi:10.1155/2017/6279859

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

ANEXOS

4.1 Anexo 1: Código de la red neuronal.

```
function [W,c,yr,ers]=Madaline(X,yd,NE,NO, alfa)
%UNTITLED2 Summary of this function goes here
% Detailed explanation goes here
NIT=200;
NDo=size(yd);
ND=NDo(1);

for i1=1:1:NIT

    ers=0;

    if i1==1

        W=randn(NO,NE);
        c=randn(NO,1);

    end

    for k=1:1:ND

        h=W*X(k,:)';
        yr(k)=c'*h;
        ek=(yd(k)-yr(k));
        ers=ers+ek^2;
        c=c+alfa*ek*h;
        W=W+alfa*ek*c*X(k,:);

    end

end

k=1:1:ND;

% plot(k,yd,k,yr)

end
```

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

4.2 Anexo 2: Código en R para las gráficas de autocorrelación

```
library(PerformanceAnalytics)
nombres<-c("3m", "American
Express", "Apple", "Boeing", "Caterpillar", "Chevron", "Cisco
Systems", "Coca-Cola", "DowDuPont", "ExxonMobil", "General
Electric", "Goldman Sachs", "The Home
Depot", "IBM", "Intel", "Johnson & Johnson", "JPMorgan
Chase", "McDonalds", "Merck", "Microsoft", "Nike", "Pfizer", "Proct
er & Gamble", "Travelers", "UnitedHealth Group", "United
Technologies", "Verizon", "Visa", "Walmart", "Walt Disney")
for(i in 1:30){
  ruta <-
"C:/Users/scorr/Documents/Universidad/Tesis/InputsR"
  ruta<-paste(ruta,nombres[i],sep="/")
  ruta<-paste(ruta,"csv",sep=".")
  assign(nombres[i],read.csv(ruta))
  assign(nombres[i],na.omit(get(nombres[i])[2:2054,1:2]))
}
for(i in 1:30){
  jpeg(paste(nombres[i],"jpg",sep="."))
  chart.ACFplus(get(nombres[i])[1900:2052,2],main =
nombres[i])
  dev.off()
}
```

4.3 Anexo 3: Código completo para correr la estrategia y backtesting

```
%Carga de datos
clear all;
close all;
clc;

vector={'3M','American
Express','Apple','Boeing','Caterpillar','Chevron','Cisco Systems','Coca-
Cola','DowDuPont','ExxonMobil','General Electric','Goldman Sachs','The
Home Depot','IBM','Intel','Johnson & Johnson','JPMorgan
Chase','McDonalds','Merck','Microsoft','Nike','Pfizer','Procter &
Gamble','Travelers','UnitedHealth Group','United
Technologies','Verizon','Visa','Walmart','Walt Disney'};

%% Encontrar retornos y varianzas esperadas
for contar=360:500

matrizprono=table(vector',zeros(length(vector'),1),zeros(length(vector'),
1),zeros(length(vector'),1));

for i=1:length(vector)
    j=1;

    datos=xlsread('Datos.xlsx',char(vector(i)));
    pr=nrm(datos(2:length(datos(:,1))-500+contar,1));
    vol=nrm(datos(2:length(datos(:,1))-500+contar,2));
    rs=nrm(datos(2:length(datos(:,1))-500+contar,3));
    pr4=pr(1:length(pr)-4);
    pr3=pr(2:length(pr)-3);
    pr2=pr(3:length(pr)-2);
    pr1=pr(4:length(pr)-1);
    yd=pr(5:length(pr));
    volumen=vol(4:length(pr)-1);
    rsi=rs(4:length(pr)-1);
    X=[pr1 pr2 pr3 pr4 volumen rsi];
    [W,c,yr,ers]=Madaline(X,yd,6,10, 0.00001);
    vp=[pr(length(pr)) pr(length(pr)-1) pr(length(pr)-2) pr(length(pr)-3)
    vol(length(pr)) rs(length(pr))];
    pron=c'*W*vp';
    matrizprono{i,2}=pron/pr(length(pr))-1;

    if matrizprono{i,2}>0
        %varianza
        mater=diff((yd)) - diff((c'*W*X'))';
        materr=mater;
        materr4=materr(1:length(materr)-4);
        materr3=materr(2:length(materr)-3);
        materr2=materr(3:length(materr)-2);
        materr1=materr(4:length(materr)-1);
        yg=materr(5:length(materr));
        Xg=[materr1 materr2 materr3 materr4];
```

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

```

[Wg,cg,yrg,ersg]=Madaline(Xg,yg,4,10, 0.00001);
vpg=[materr(length(materr)) materr(length(materr)-1)
materr(length(materr)-2) materr(length(materr)-3)];
matrizprono{i,3}=(cg'*Wg*vpg').*(cg'*Wg*vpg');
%vector retornos
retorno(:,j)=diff(log(yd));
j=j+1;
end
close all

end
%Construir matriz CCC
matrizprono.Properties.VariableNames = {'Stock' 'Return' 'Variance'
'wfinal'};

rows = matrizprono.Return>0;
matrizprono=matrizprono(rows,:);

nd=length(datos);
nac=sum(matrizprono{:,2}>0);

varmar=zeros(nac,nac);
for i=1:nac
    varmar(i,i)=(matrizprono{i,3})^(1/2);
end
corrmat=corrcoef(retorno);
cccm=varmar*corrmat*varmar;

%Optimizar vector Ws
wf=zeros(nac,1);
retvaropt=0;
for i=1:100000
    w=abs(randn(nac,1));
    w=w/sum(w);
    retvar=(w'*matrizprono{:,2})/(w'*cccm*w);
    if retvaropt<retvar
        retvaropt=retvar;
        wf=w;
    end
end
matrizprono{:,4}=wf;
filename = char(strcat(num2str(contar),'.xlsx'));
writetable(matrizprono,filename)

clear c cg datos ers ersg i k mater materr materr1 materr2 materr3
materr4 nac nd pr pr1 pr2 pr3 pr4 pron retorno rows rs rsi varmar vol
volumen vp vpg W Wg X Xg yd yg yr yrg cormat w retvar corrmat wf
filename matrizprono cccm j retvaropt

end

```

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

4.4 Anexo 4: Código usado para generar outputs de Simulink

```
%% leer datos de excel
%"The Home Depot","IBM"
data=xlsread('Coca-Cola.xlsx');
price=data(:,1);
volume=data(:,2);
RSI=data(:,3);
% cargar vectores de variables mas importantes
k1=1:1:2050;

xf1=price(1:1:2050,1);
xv1=volume(1:1:2050,1);
xp1=RSI(1:1:2050,1);

maxxf1=max(xf1);
minxf1=min(xf1);
xnfl=(2/(maxxf1-minxf1))*(xf1-maxxf1)+1;%formula para normalizar

maxxv1=max(xv1);
minxv1=min(xv1);
xnv1=(2/(maxxv1-minxv1))*(xv1-maxxv1)+1;%formula para normalizar

maxxp1=max(xp1);
minxp1=min(xp1);
xnp1=(2/(maxxp1-minxp1))*(xp1-maxxp1)+1;%formula para normalizar

% Crear estructuras para ingresar a simulink
x=[xnfl xnp1 xnv1];

wave.time=k1;
wave.signals.values=x;%una sola columna
wave.dimension=3;%sólo un vector, una sola variable.

ne=8;
no=10;%pueden ser hasta 8164/5 pero allí hay ecuaciones redundantes
clear n maxxfl maxxpl maxxv1 maxyd minxf1 minxv1 minxp1 minyd Breath
Datum Timems Status OptionalPressurecmH2O PressurecmH2O Volumemls Flowmls
HHMMSS xf1 xp1 xv1

%%
filename = 'Coca-ColaR.xlsx';
xlswrite(filename,WF(:, :, 18))

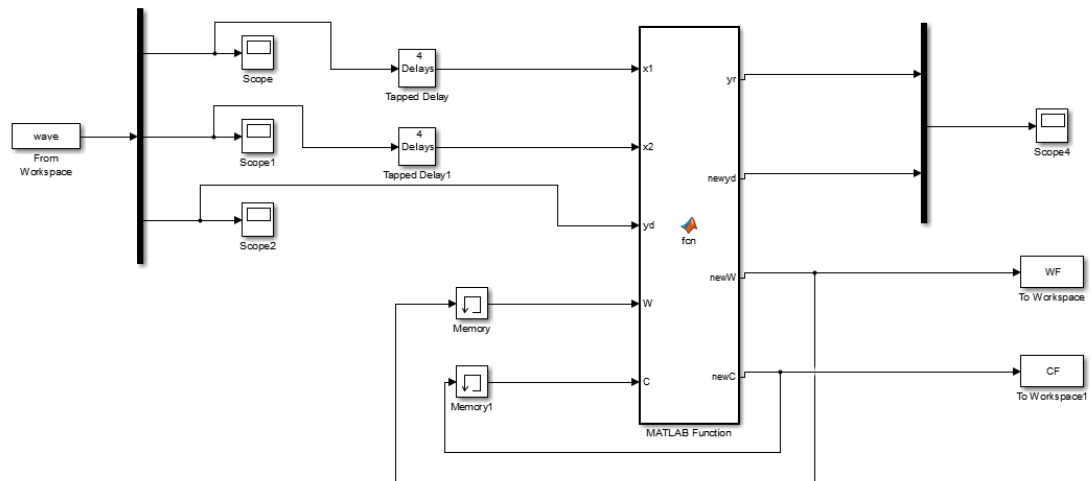
%#codigo del entrenamiento de la red neuronal
function [yr,newyd,newW,newC] = fcn(x1,x2,yd,W,C)
%#codegen
alfa=0.01;
X=[x1' x2'];
h=W*X';
yr=C'*h;
```

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.


```

ek=yd-yr;
C=C+alfa*ek*h;
W=W+alfa*ek*C*X;
newW=W;
newC=C;
newyd=yd;

```



Scope 1 2 y 3 son las variables precio, volumen y RSI respectivamente. La variable de salida es la serie de precios.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.